

PONTIFICIA UNIVERSIDAD CATÓLICA DEL PERÚ

Escuela de Posgrado



PONTIFICIA
UNIVERSIDAD
CATÓLICA
DEL PERÚ

**SELECCIÓN DE TAREAS PREDEFINIDAS PARA UN ROBOT
ASISTENCIAL PARA PERSONAS DISCAPACITADAS A TRAVÉS
DE UNA INTERFAZ CEREBRO-COMPUTADOR UTILIZANDO**

P300

Tesis para optar al grado de Magíster en Ingeniería Mecatrónica

Presentado por:
JUAN MANUEL CHAU DELGADO

Asesor:
DAVID RONALD ACHANCCARAY DÍAZ, M.SC.

Octubre 2018
Lima - Perú



©2018, Juan Manuel Chau Delgado

Se autoriza la reproducción total o parcial,
con fines académicos a través de cualquier
medio o procedimiento, incluyendo la cita
bibliográfica del documento.

RESUMEN

En la actualidad, es común presenciar el desarrollo de aplicaciones de ingeniería orientadas a la mejora de calidad de vida de personas, tanto para las que han sufrido accidentes, como para las que poseen deficiencias congénitas. En el caso de las personas cuyas discapacidades son neurológicas, las aplicaciones de rehabilitación, reincorporación, según se busque devolver facultades, o proveer medios de reemplazo para habilidades perdidas, requieren de una interfaz cerebro-computador, que se encarga de medir ciertos patrones en las señales cerebrales de los pacientes y traducirlos para que una computadora pueda interpretarlas.

El presente trabajo comprende el diseño de una interfaz cerebro-computador que, aplicando algoritmos de procesamiento de señales cerebrales y aprendizaje de máquina, permite a un usuario seleccionar diversas tareas predefinidas para un manipulador robótico asistencial aprovechando el potencial relacionado a eventos conocido como P300. Adicionalmente, también se presenta una propuesta experimental para las realizaciones de pruebas, tanto fuera de línea como en línea del sistema, de manera que se pueda analizar y validar su eficiencia y usabilidad. Finalmente, se analizan resultados no cuantitativos provenientes de los usuarios, que pueden ser utilizados para futuros estudios relacionados.

Dentro de los resultados de eficiencia del sistema se obtienen valores promedio alrededor de 90 % para los experimentos de entrenamiento, y cercanos a 85 % para la validación si se considera una secuencia de tres estímulos antes de que el sistema emita una predicción durante las pruebas en línea; sin embargo, los usuarios reportan que se podría mejorar la calidad del sistema si se realizan algunas mejoras, como la calidad de las imágenes mostradas como estímulos, y el contraste con el color de fondo.

AGRADECIMIENTOS

- A mi mamá, por el apoyo y motivación incondicional durante estos dos años, sobretodo en los momentos más difíciles.
- A mi asesor, David Achanccaray Díaz, M.Sc., por la confianza depositada en mí durante todo el tiempo en el que hemos trabajado juntos, y por el apoyo para seguir esforzándome y alcanzando nuevos objetivos.
- A Elizabeth Villota, PhD., por ser una de las primeras personas que me inspiró a seguir el camino de la investigación, y por invitarme a ser parte del proyecto del que este trabajo forma parte.
- A Concytec, Cienciaactiva y la Pontificia Universidad Católica del Perú por el financiamiento del proyecto que permitió el desarrollo de la presente.
- A Dante Elías, PhD. y a los miembros del Grupo de Investigación en Biomecánica y Robótica aplicada, por la cordialidad con la que inicialmente me recibieron, y por la amistad desarrollada durante el tiempo que llevo como parte de su equipo.



“My life is my message.”

Mohandas Karamchand Gandhi

ÍNDICE GENERAL

RESUMEN	I
AGRADECIMIENTOS	II
DEDICATORIA	III
ÍNDICE DE TABLAS	VII
ÍNDICE DE FIGURAS	VIII
INTRODUCCIÓN	1
1. ANTECEDENTES	3
1.1. Interfaz Cerebro-Computador	3
1.1.1. Historia	4
1.1.2. Componentes	4
1.1.3. Adquisición de Datos	6
1.1.4. Paradigmas	11
1.1.5. Aplicaciones	14
1.2. Robótica Asistencial con BCI	20

1.2.1.	Aplicaciones que utilizan ERD/ERS	21
1.2.2.	Aplicaciones que utilizan SSEP	23
1.2.3.	Aplicaciones que utilizan ERP	24
2.	DESARROLLO DEL SISTEMA	27
2.1.	Configuración Gráfica para el Usuario	27
2.2.	Adquisición de Datos	30
2.3.	Preprocesamiento de Señales	30
2.4.	Extracción de Características	33
2.5.	Clasificación	37
2.6.	Comunicación con el Robot Asistencial	40
2.7.	Configuración Experimental	40
2.7.1.	Definiciones Básicas	41
2.7.2.	Experimento Fuera de Línea	43
2.7.3.	Experimento En Línea	43
2.7.4.	Ambiente para Experimentación	44
3.	RESULTADOS Y DISCUSIÓN	46
3.1.	Resultados de Entrenamiento	46
3.2.	Resultados de Validación	49
3.3.	Resultados no Cuantitativos	50
	CONCLUSIONES	53

RECOMENDACIONES	54
BIBLIOGRAFÍA	55
ANEXOS	63



ÍNDICE DE CUADROS

1.1. Descripción de componentes funcionales de una BCI.	5
1.2. Lazos de realimentación presentes en una BCI.	6
3.1. Resultados promedio con desviación standard para validación cruzada y entrenamiento final por usuario.	48
3.2. Resultados promedio con desviación standard para validación del sistema por usuario.	49
3.3. Resultados no cuantitativos por usuario según método utilizado para concentrarse.	50
3.4. Resultados no cuantitativos por usuario según mejoras a realizarse para el sistema.	51

ÍNDICE DE FIGURAS

1.1. Modelo funcional propuesto de un sistema de BCI	5
1.2. Data obtenida por electroencefalografía	7
1.3. Representación de electrodos secos mostrada en el trabajo de Lopez-Gordo et al	8
1.4. Distribución de electrodos de EEG según Sistema Internacional 10/20	9
1.5. Comparación de respuestas P300 en usuarios con y sin discapacidad	12
1.6. SSVEP producido por un parpadeo de 12Hz en el lado izquierdo del campo visual	13
1.7. Ejemplo de procesamiento para ERD y ERS	15
1.8. Matriz de caracteres utilizada por un deletreador P300	16
1.9. Control de robot para traslado de objetos usando ondas alfa	17
1.10. Usuario utilizando BCI para sostener un lapicero y escribir	18
1.11. Gráficos de distribución de juegos desarrollados	19
1.12. Diferencias espectrales en condiciones de alto y bajo stress	20
1.13. Prótesis de mano controlada con un sistema BCI	22

1.14. Diagrama de flujo de sistema integrado para control con EEG y EMG	23
1.15. Montaje de sistema para control de silla de rueda basado en SSEP	24
1.16. Interfaz gráfica y robot humanoide controlado por sistema BCI . .	25
1.17. Interfaz gráfica utilizada para el experimento de Hoffmann et al .	26
2.1. Diagrama de flujo de interfaz gráfica para el usuario.	28
2.2. Primer nivel de navegación del sistema con dos posibles estímulos.	28
2.3. Segundo nivel de navegación del sistema con tres posibles estímulos.	29
2.4. Flujo de navegación de interfaz para el usuario.	29
2.5. Posición de electrodos según Sistema Internacional 10/10.	31
2.6. Esquema de comunicación entre aplicaciones de adquisición y muestra de estímulos.	32
2.7. Diagramas de magnitud y fase para el filtro digital diseñado. . . .	33
2.8. Señales para estímulo objetivo y estímulo no objetivo.	34
2.9. Señales para estímulo objetivo iniciales y filtradas con CSP.	36
2.10. Características extraídas con CSP en el nuevo subespacio para señales de estímulo objetivo y estímulo no objetivo.	37
2.11. Características antes y después de normalización para estímulo objetivo.	38
2.12. Esquema de comunicación entre todas las aplicaciones necesarias.	41
2.13. Diagrama de clases para entidades temporales de un sistema BCI.	42
2.14. Línea de tiempo para un <i>trial</i> de adquisición.	43

2.15. Línea de tiempo para un *trial* de validación. 44

3.1. Resultados de validación cruzada con seis grupos para el sujeto 1. 47

3.2. Resultados de entrenamiento de clasificador final para sujeto 1. . . 48



INTRODUCCIÓN

Cerca del final de la década de 1960, ya se publicaban estudios que mostraban animales siendo recompensados por dispositivos robóticos a partir del disparo de múltiples neuronas en la corteza motriz primaria de sus cerebros, en función de un aprendizaje con refuerzos positivos [1]. Algunos años más tarde, en la década de 1980, se descubrió una relación matemática entre la actividad cerebral de los monos y la dirección hacia la que movían sus brazos [2].

Desde entonces, y con la aparición de la primera prueba de electroencefalograma en humanos, se han desarrollado diversas aplicaciones usando la información que se puede extraer de las señales cerebrales, tanto para rehabilitación, como para reemplazo de ciertas capacidades o actividades. Dichas aplicaciones pueden ser utilizadas casi por cualquier persona consciente, debido a que solo se requiere que aprendan a controlar su actividad cerebral; es decir, a generar ciertos patrones que puedan ser interpretados por un sistema de procesamiento, y que los convertirá en acciones específicas a ser realizadas por dispositivos externos. A esta tecnología se le conoce como interfaz cerebro-computador.

Dentro de los diversos patrones que se pueden encontrar en las señales cerebrales se encuentra la componente P300, asociado con la atención de una persona frente a un estímulo visual de duración limitada. Con esta componente se pueden realizar diversas aplicaciones, entre las que resaltan las de construcción de palabras mediante deletreo; sin embargo, también es posible usar una metodología similar para componer tareas complejas a partir de una combinación de opciones.

El interés científico para el desarrollo del sistema propuesto radica en la imple-

mentación de un sistema de detección de patrones cerebrales específicos para convertirlos en acciones reales dentro del entorno de los usuarios, además del diseño de los experimentos y protocolos necesarios para la adquisición correcta de datos y validación del sistema. Es importante resaltar también que dichos experimentos pueden ser utilizados con personas con discapacidades físicas o neurológicas sin requerir de modificaciones significativas; sin embargo, como la literatura lo indica, no es necesaria la realización de estos procedimientos para validar el sistema [3] [4].

La relevancia de la presente radica en la gran diversidad de aplicaciones con dispositivos periféricos que pueden ser desarrolladas posteriormente sin necesidad de realizar modificaciones mayores sobre el núcleo del sistema. Es importante resaltar, también, que aplicaciones que requieran de respuestas de alta velocidad por parte del usuario no son compatibles con este tipo de sistema, a menos que se incluyan módulos de inteligencia artificial con suficiente robustez para evitar poner en peligro su integridad física.

Finalmente, dentro de los alcances contemplados se encuentran el desarrollo de una interfaz cerebro-computador y la implementación de algoritmos de procesamiento de señales y aprendizaje de máquina para realizar la identificación de las señales cerebrales, el desarrollo de los procedimientos experimentales para el uso del sistema, y el análisis de la eficiencia del sistema desarrollado, además de la comunicación con los dispositivos periféricos; sin embargo, no se considerará el desarrollo del hardware requerido para realizar dichas tareas.

CAPÍTULO 1

ANTECEDENTES

En el presente capítulo se expone una breve descripción de la evolución tecnológica de los sistemas desarrollados alrededor de Interfaces Cerebro-Computador (BCI), además de un análisis de las aplicaciones que utilizan robots asistenciales para mejora de calidad de vida de personas con discapacidad a causa de accidentes cerebro-vasculares (ACV). A partir de ambas, se propone, más adelante, una aplicación integrada que realice tareas predefinidas seleccionadas por el usuario.

1.1 Interfaz Cerebro-Computador

Como se definió en la primera reunión internacional sobre tecnología para interfaces cerebro-computador (BCI), una Interfaz Cerebro-Computador es un sistema “que otorga a los usuarios canales de control y comunicación que no dependen de los caminos normales de salida del cerebro hacia nervios periféricos y músculos” [5]. El desarrollo de esta tecnología implica una posibilidad de aumento de calidad de vida en pacientes parcial o totalmente paralizados al verse afectados por esclerosis lateral amiotrófica o una severa parálisis cerebral, al devolverles la posibilidad de interactuar con su entorno, controlarlo, desplazarse, o comunicarse sin ayuda.

“Es importante resaltar que, aunque solo requieren actividad neuronal, las interfaces cerebro-computador utilizan actividad neuronal generada voluntariamente por el usuario” [6]; esto implica que los sistemas controlados por una BCI no pue-

dan cambiar de estado accidentalmente, sino que siempre estén bajo el control del usuario, incluso en caso de una emergencia como un ataque epiléptico.

1.1.1 Historia

En 1929, el psiquiatra Hans Berger publicó su trabajo sobre el primer electroencefalograma [7], lo que causó especulación durante muchos años sobre la posibilidad de crear sistemas de control que utilizaran las señales eléctricas del cerebro como entrada.

La especulación originada por el trabajo de Berger terminaría en los años 70, cuando el psicólogo de la Agencia de Investigación de Proyectos Avanzados de Defensa de los Estados Unidos (DARPA), George Lawrence, empezó un proyecto para utilizar las señales originadas en el cerebro para desarrollar técnicas con el objetivo de mejorar el desempeño de los soldados. Su investigación produjo una visión general de biorretroalimentación; es decir, de la realimentación obtenida de sistemas orgánicos, y dió el origen al estudio del campo de la biocibernética.

En 1973, el director del Laboratorio de Interfaces Cerebro-Computador de la Universidad de California, Los Angeles (UCLA), Jacques Vidal [8], evidenció la posibilidad de controlar el desplazamiento de un cursor en un laberinto bidimensional a partir de señales cerebrales que se generaban a partir de un estímulo visual proveniente de una computadora. A partir de este trabajo se pudo diferenciar a los sistemas de control que utilizaban actividad registrada por electromiografía; es decir, señales generadas a en los tejidos musculares, de aquellos que utilizaban actividad registrada por electroencefalografía.

1.1.2 Componentes

En el año 2003, Mason et al. [9] propusieron un modelo funcional de BCI para resolver las dificultades notadas por Wolpaw et al. [5] al comparar tecnologías

existentes. El modelo propuesto, mostrado en la Figura 1.1, tuvo como objetivos principales facilitar la identificación y comparación de los componentes funcionales entre los diversos sistemas desarrollados, además de definir un vocabulario común a ser utilizado en futuros trabajos. Dichos componentes funcionales se describen en la Tabla 1.1.

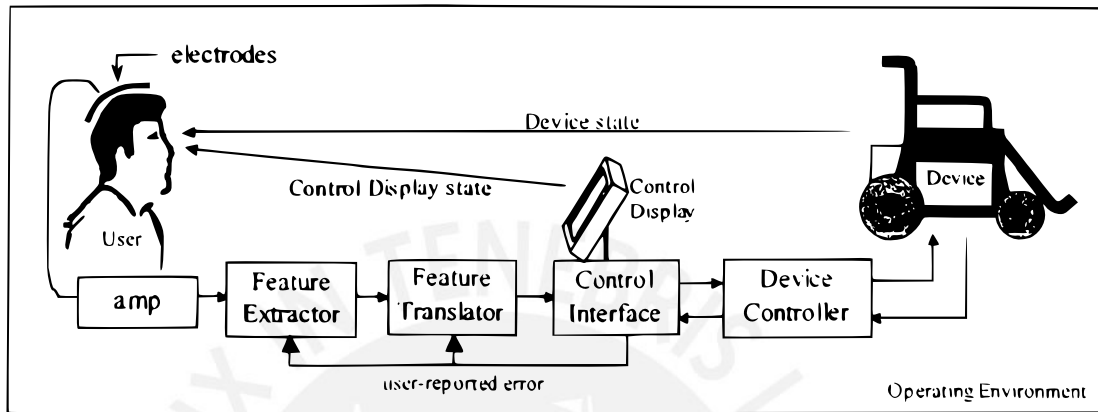


Figura 1.1: Modelo funcional propuesto de un sistema de BCI [9].

Tabla 1.1: Descripción de componentes funcionales de una BCI.

Componente	Descripción
Usuario	Persona a cargo del control del sistema.
Electrodos	Convierten los estados cerebrales del usuario en señales eléctricas.
Amplificador	Amplifica y filtra la señal obtenida por los electrodos.
Extractor de características	Extrae valores que representen las características principales, a modo de síntesis, de la señal amplificada.
Traductor de características	Clasifica la señal según los valores característicos en señales de control lógicas independientes del dispositivo.
Interface de control	Convierte la señal de control lógica en una señal de control semántica para un dispositivo en particular.
Controlador de dispositivo	Convierte las señales de control semánticas en señales de control físicas para el dispositivo a utilizar.
Dispositivo	Es el actuador del sistema. Puede ser una órtesis, un monitor, un robot móvil, etc.
Ambiente de operación	Condiciones de operación del sistema como iluminación, aislamiento auditivo y temperatura.

Fuente: Adaptado de [9].

Además de definir los componentes funcionales de una BCI, en el mismo trabajo se consideró importante definir los diversos lazos de realimentación que se pueden encontrar contenidos en dichos sistemas con el mismo objetivo, de manera que

esta referencia también pueda utilizarse para comparaciones mutuas de futuros estudios. Los lazos definidos se encuentran descritos en la Tabla 1.2.

Tabla 1.2: Lazos de realimentación presentes en una BCI.

Lazo de realimentación	Descripción
Estado del dispositivo	Realimentado al usuario a partir de canales sensoriales.
Estado de monitor de control	Informa al usuario sobre el estado de la interfaz de control.
Estado de controlador de dispositivo	Informa a la interfaz de control sobre la instrucción semántica en progreso.
Errores reportados por el usuario	Se usan en caso el extractor o traductor de características sean adaptativos.
Estado del usuario	Percepción del usuario sobre su propio estado.
Estado del ambiente	Se percibe según los objetos y personas en el entorno.

Fuente: Adaptado de [9].

Finalmente, también se consideró conveniente incluir la taxonomía básica para el diseño de sistemas BCI, mencionando incluso algunos ejemplos, facilitando la interpretación y uso de diseños ya publicados. Para identificar los puntos considerados por dicha taxonomía, se tomó en cuenta su fácil comprensión a partir de los elementos funcionales de un sistema BCI. Los puntos en mención son la población objetivo, las tareas objetivo, el ambiente de operación objetivo, el controlador de la BCI, la interfaz de control, el dispositivo y el controlador del dispositivo.

1.1.3 Adquisición de Datos

Existen diversos métodos para obtener la información necesaria para un sistema basado en una BCI. Estos procedimientos pueden ser invasivos o no invasivos; es decir, pueden o no requerir cirugía o instalación de componentes en la corteza cerebral de los pacientes, o la adquisición de equipos con un volumen mayor y un costo más alto también.

i. Electroencefalografía (EEG)

Electroencefalografía es una representación gráfica de la diferencia de voltaje entre dos posiciones cerebrales diferentes, dibujada sobre el tiempo [10]. La actividad eléctrica cerebral genera unas mínimas señales eléctricas que pueden ser captadas mediante electrodos situados sobre el cuero cabelludo [11], por lo que es un proceso no invasivo. Las señales obtenidas, similares a las que se muestran en la Figura 1.2, son luego procesadas para rescatar información relevante sobre el estado cerebral del paciente. En medicina, este proceso se utiliza para diagnósticos de epilepsia; sin embargo, también puede utilizarse para desarrollar aplicaciones de BCI. En la actualidad, es uno de los procesos de adquisición de información más comunes en dichos sistemas, ya que existen diversos dispositivos portátiles y de costo relativamente bajo en el mercado.



Figura 1.2: Data obtenida por electroencefalografía [10].

Existen diversos tipos de sensores que se pueden colocar en la superficie del pericráneo de los usuarios para realizar pruebas, y están divididos en dos grandes grupos: los electrodos húmedos, que requieren de gel conductor para su aplicación,

y los electrodos secos, que no lo requieren. Los electrodos húmedos más usados son pequeños discos de plata y cloruro de plata u oro. Los electrodos también pueden clasificarse como pasivos y activos [12]. Así, un electrodo pasivo se refiere solo al sensor colocado sobre la cabeza del usuario; mientras que un electrodo activo incluye también un amplificador y un filtro además del sensor, para evitar que la señal obtenida sea afectada por perturbaciones del ambiente.

M. A. Lopez-Gordo et al. [13] sintetizan, en su trabajo, sobre electrodos secos para EEG, los diferentes tipos de electrodos secos que se pueden utilizar para realizar un electroencefalograma, y hacen referencia a sus desarrollos. En dicho trabajo se menciona también la comparación de rendimiento, si es que se realizó, entre cada electrodo desarrollado frente a los electrodos húmedos; ya que estos son los que logran obtener mejor resolución de data, debido a que el gel permite a la capa metálica del sensor conectarse adecuadamente con la piel del usuario aún a través del cabello. Algunos de los electrodos mencionados en dicho trabajo están representados en la Figura 1.3.




Figura 1.3: Representación de electrodos secos mostrada en el trabajo de Lopez-Gordo et al [13].

Existen diversas formas de colocar los electrodos. La cantidad de puntos a con-

siderar se determina según la cantidad y tipos de señales que se deseen obtener; sin embargo, existen varios sistemas de posicionamiento de electrodos a tomar en cuenta [14]. Sus nombres están basados en las posiciones relativas al pericráneo del usuario; por ejemplo, el Sistema Internacional 10/20 [15], divide la superficie pericraneal en zonas verticales y horizontales de diez y veinte por ciento de la longitud total, colocando electrodos en los puntos de intersección de las líneas imaginarias usadas para la división, como se muestra en la Figura 1.4.




Figura 1.4: Distribución de electrodos de EEG según Sistema Internacional 10/20 [15].

ii. Otros Métodos

La electrocorticografía (ECoG), también conocida como electroencefalografía intracraneal, consiste en colocar los electrodos directamente sobre la superficie cerebral, luego de realizar una sección craneal mediante cirugía, para monitorear la actividad de la corteza cerebral. Fue desarrollada por los neurocirujanos Wilder Penfield y Herbert Jasper para identificar por medio de los potenciales encontrados las zonas que causaban ataques epilépticos en pacientes. La ventaja de este procedimiento sobre el mencionado anteriormente es que, al estar los electrodos tan cerca del lugar donde se originan las señales, se pueden adquirir y monitorear estas con una mayor resolución y menor contaminación ruidosa.

La espectroscopía funcional del infrarrojo cercano (fNIRS) analiza las concentraciones de oxígeno en la sangre en las diferentes áreas del cerebro a partir de la absorción de luz cercana al espectro infrarrojo, con el objetivo de determinar diversos patrones de actividad asociados; sin embargo, debido a la complejidad de estos modelos, se requiere conocimiento adicional en modelamiento a nivel celular y molecular para realizar las interpretaciones adecuadas.

Adicionalmente, existen otros métodos para analizar los estados cerebrales de pacientes y sujetos de prueba de manera no invasiva. Entre ellos se encuentran los diversos tipos de tomografía computarizada (CT), imagen por resonancia magnética (MRI), magnetoencefalografía (MEG), entre otros; sin embargo, los equipos necesarios para realizar cada uno de estos procedimientos ocupan un volumen considerablemente alto, requieren de un ambiente de operación con estrictas condiciones de aislamiento, y poseen un precio bastante elevado en comparación a los utilizados para EEG, por lo que deben ser descartados cuando se considera desarrollar sistemas prácticos o portátiles.

1.1.4 Paradigmas

Se les conoce así a los patrones que se pueden detectar en las ondas cerebrales mediante EEG y otros métodos. Están agrupados según la estimulación requerida para su ocurrencia, y cada grupo requiere diversas técnicas de procesamiento de señales para la extracción de características relevantes.

i. Potenciales Relacionados a Eventos (ERP)

Observados por primera vez por Richard Caton, pueden ser definidos como “cambios electroencefalográficos asociados con el tiempo a eventos sensoriales, motores o cognitivos” [16]; es decir, son ondas que se generan como respuesta a un evento en el que el usuario se encuentra involucrado: un intento de movimiento, un estímulo visual o auditivo, etc.

Los componentes de los ERP que presentan formas de pico de voltaje reciben nombres según el valor máximo que presentan, positivo o negativo, y el tiempo aproximado en milisegundos de desfase con el evento en el que ocurre dicho pico de voltaje. Uno de los potenciales relacionados a eventos más utilizados en la actualidad es la onda P300, también conocida como P3. “La onda P3 fue descubierta por Sutton et al. en 1965 y ha sido desde entonces el componente mayor de la investigación en el campo de ERP” [16], y es llamada así por tener un pico positivo característico que ocurre aproximadamente 300 milisegundos después del estímulo, como se aprecia en la Figura 1.5. Dicha onda suele estar relacionada con el proceso de toma de decisiones.

Otro de los componentes de los ERP se genera según la equivocación del sujeto al realizar tareas basadas en elección [18]. A este componente se le conoce como potencial relacionado a error, y es investigado para confirmar que la acción tomada por el usuario durante el uso de un sistema BCI corresponde a su intención, mejorando significativamente la precisión del sistema.

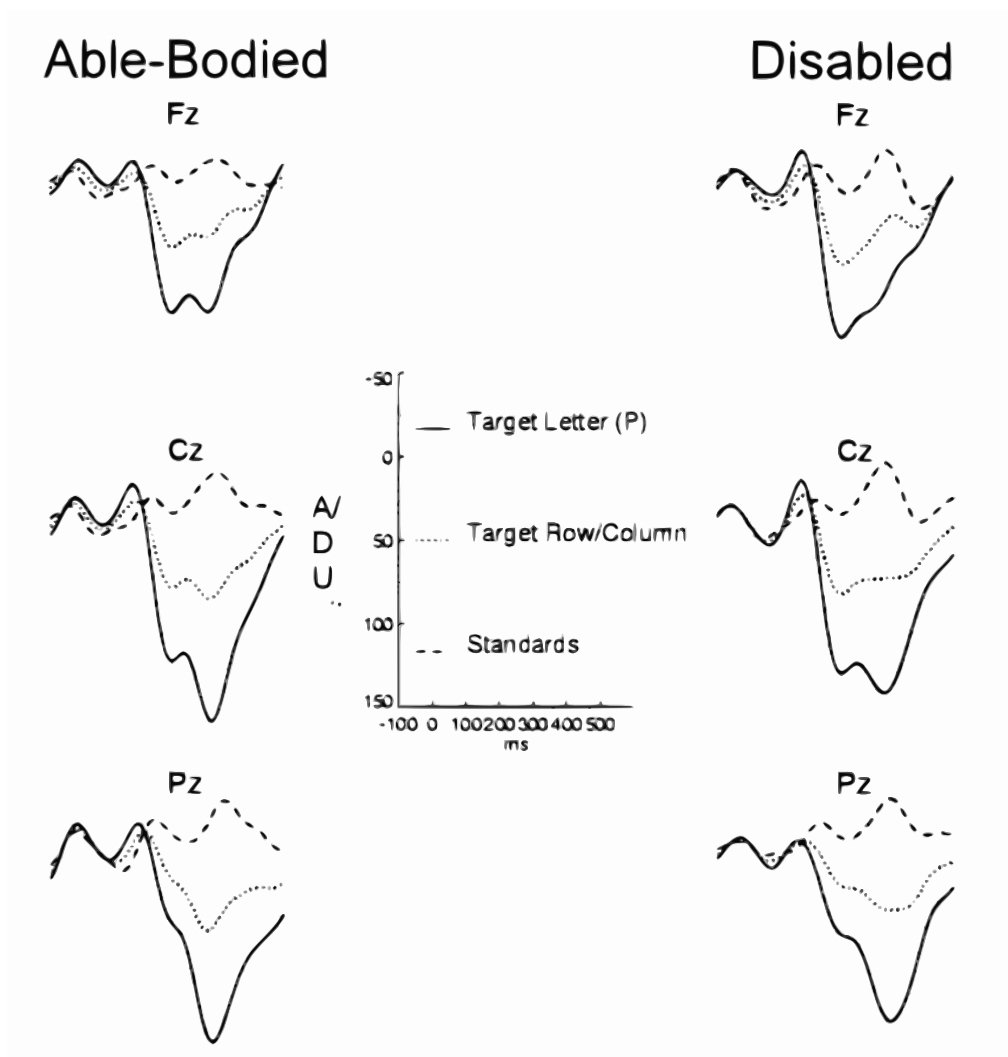


Figura 1.5: Comparación de respuestas P300 en usuarios con y sin discapacidad [17].

ii. Potenciales Evocados en Estado Estable (SSEP)

D. Regan [19] analizó las frecuencias de la respuesta a la exposición prolongada de una luz monocromática de intensidad sinusoidalmente modulada y observó que, luego de la respuesta transitoria; es decir, cuando los usuarios se acostumbraban a la perturbación, aparecía una señal independiente de las ondas alfa con un desfase proporcional a la frecuencia del estímulo. Las señales más utilizadas en este campo son generadas a partir de secuencias prolongadas de estímulos visuales o auditivos secuenciales sobre los cuales el usuario debe concentrar su atención.

Uno de los SSEP más utilizados es el potencial visual evocado en estado estable (SSVEP), precisamente el que fue observado por Regan. Sus modulaciones han sido asociadas a un número de variables cognitivas como la atención, clasificación y búsqueda de memoria [20]. Otras variables del estímulo como el contraste y la frecuencia espacial también tienen influencia sobre la amplitud y fase de los SSVEP [21]. Finalmente, la posición relativa del estímulo en el campo visual del usuario también tendrá un impacto sobre las características de un SSVEP, como se aprecia en la Figura 1.6.

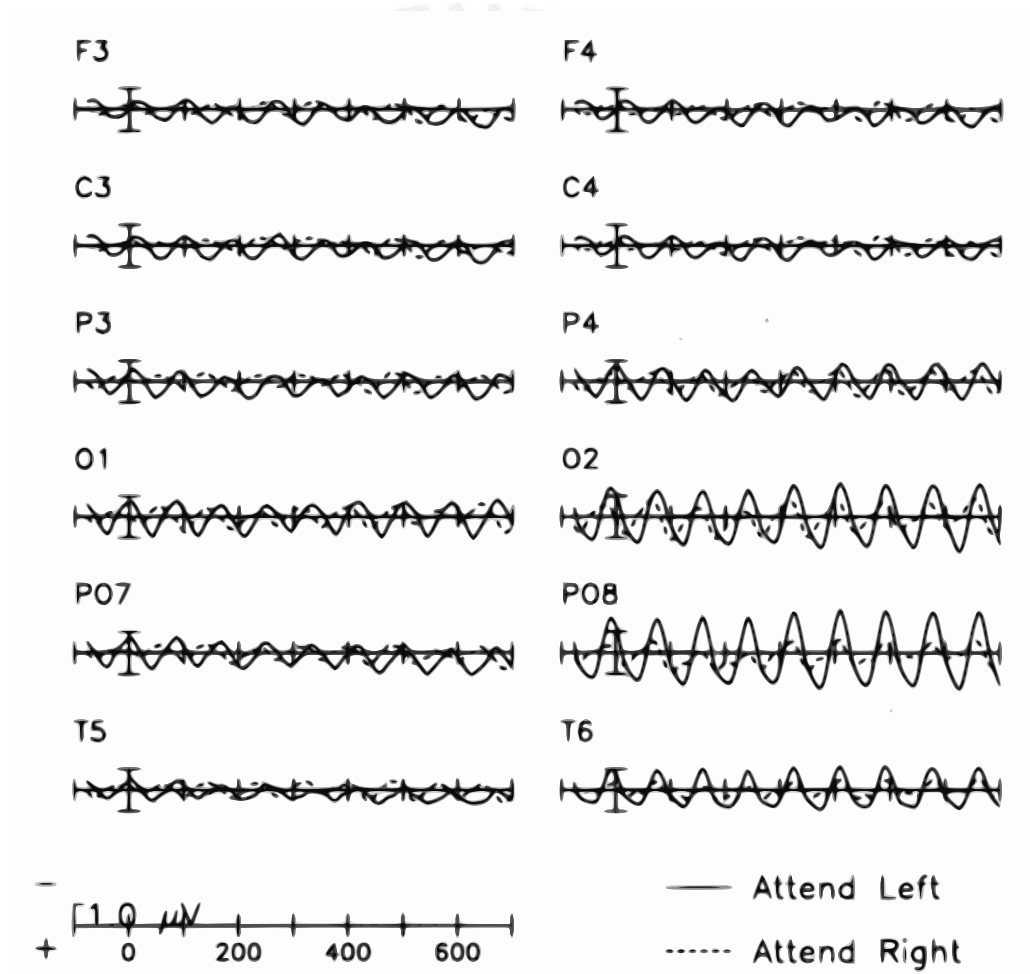


Figura 1.6: SSVEP producido por un parpadeo de 12Hz en el lado izquierdo del campo visual [21].

Otro de los SSEP comúnmente estudiados es la respuesta en estado estable auditiva (ASSR), asociada a la atención consciente o inconsciente del usuario sobre estímulos auditivos en determinadas frecuencias [22]. Algunas aplicaciones ba-

sados en ASSR pueden ser utilizadas para medir la capacidad auditiva [23]; sin embargo, también hay estudios que demuestran que es posible utilizar esta respuesta en sistemas para usuarios con dificultades visuales o incapacidad para realizar ciertas tareas mentales [24].

iii. **Sincronización o Desincronización Relacionada a Eventos (ERD/ERS)**

Los ritmos internos del cerebro son patrones sincrónicos que involucran grandes cantidades de neuronas y están asociados a una actividad específica de la persona. Pfurtscheller et al. [25] observaron que era posible atenuar o amplificar los ritmos internos del cerebro mediante acciones específicas, a esto se le conoce como sincronización o desincronización relacionada a eventos. Por ejemplo, las comúnmente usadas ondas mu están asociadas a las imágenes motrices (MI); es decir, al movimiento voluntario de alguna parte del cuerpo de una persona, o al intento de esta por lograr dicho objetivo. Las ondas alfa, asociadas con el descanso de la persona también son bastante usadas para el desarrollo de interfaces cerebro-computador, ya que estas pueden ser amplificadas cerrando los ojos. Adicionalmente, el procesamiento de señales generadas suele realizarse en bandas de frecuencia muy específicas, según la naturaleza del evento, como se muestra en la Figura 1.7.

1.1.5 Aplicaciones

En la actualidad se buscan desarrollar diversas aplicaciones con sistemas BCI. Hay cinco áreas mayores de aplicación de BCI en las que individuos discapacitados pueden beneficiarse de avances en tecnología BCI, estas son Comunicación y Control, Sustitución Motora, Entretenimiento, Recuperación Motora y Monitoreo de estado Mental [26]; sin embargo, no todas las aplicaciones benefician exclusivamente a individuos discapacitados, sino que en general proveen alguna mejora a la calidad de vida del usuario, como ocurre en el caso de las aplicaciones

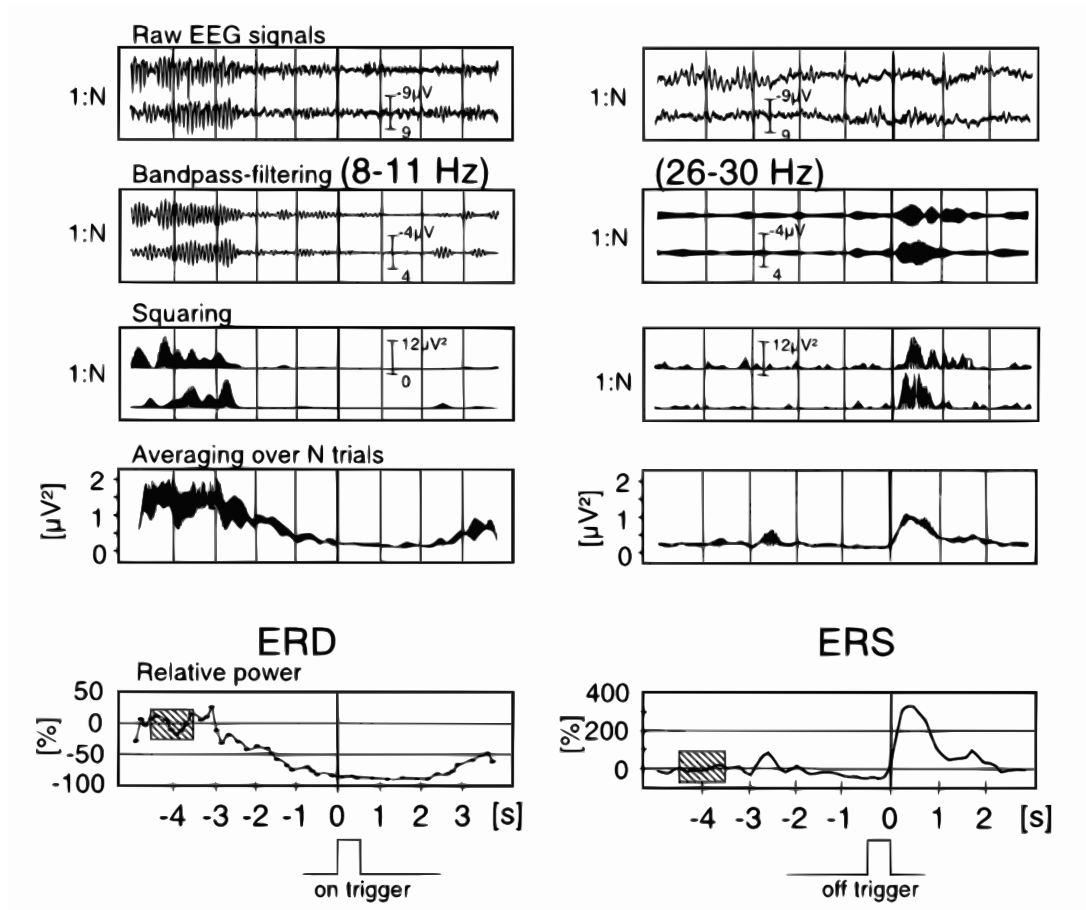


Figura 1.7: Ejemplo de procesamiento para ERD y ERS [25].

para entretenimiento, que pueden ser utilizadas en casos de rehabilitación, como realimentación, o para una mejora de experiencia en general.

i. Comunicación y Control

La investigación para establecer funciones de comunicación estuvo mayormente enfocada en aplicaciones de escritura (deletrear), y navegación (búsqueda) por internet, por lo que se han desarrollado varias aplicaciones que permiten a los usuarios utilizar pocas instrucciones de MI. Los enfoques encontrados con mayor frecuencia son los que incluyen un componente P300, debido a su practicidad y facilidad de uso para los usuarios con discapacidad [17]; sin embargo, también es posible utilizar SSVEP para teclados virtuales [27].

En el año 2006 D. J. Krusienski et al. [28] publicaron una comparación de diver-

Los algoritmos de clasificación para una BCI de deletreo basada en P300, similar a la mostrada en la Figura 1.8. Las señales fueron filtradas, amplificadas y digitalizadas, para luego ser clasificadas con diversos métodos como la correlación de Pearson (PCM), el discriminante lineal de Fisher (FLD), el análisis de discriminante lineal por pasos (SWLDA), la máquina de vectores de soporte lineal (LSVM), y la máquina de vectores de soporte con kernel Gaussiano (GKSVM), obteniendo mejor desempeño práctico con SWLDA y FLD.



Figura 1.8: Matriz de caracteres utilizada por un deletreador P300 [28].

En el año 2008, Inoue et al. [29] desarrollaron el control de un brazo robótico para realizar el traslado de un objeto de una posición a otra utilizando ondas alfa y un interruptor rápido para la selección de instrucción [30]. Las señales fueron filtradas antes de contar el tiempo durante el que el usuario incrementa la

amplitud de la onda alfa para poder realizar el cambio de instrucción. Algunas escenas de dicho experimento se pueden apreciar en la Figura 1.9.



Figura 1.9: Control de robot para traslado de objetos usando ondas alfa [29].

ii. Sustitución Motriz

Como su nombre lo indica, consiste en reemplazar la capacidad de movimiento del usuario, ya sea con una prótesis; es decir, con una extensión artificial del cuerpo, o con una órtesis, cuyo objetivo es complementar a alguna parte del cuerpo. “La restauración de funciones de agarre en pacientes con la médula espinal dañada (SCI) o pacientes que sufren de parálisis en las extremidades superiores típicamente se apoya en la estimulación funcional eléctrica (FES)” [26].

La primera integración de un sistema BCI con FES fue realizada por G. Pfurtscheller et al. [31] en el año 2003 con señales de MI filtradas, y utilizando FLD como clasificador. Posteriormente, en el año 2010, M. Tavella et al. [32] desarrollaron un sistema de BCI que permitía a los usuarios tomar un lapicero y escribir palabras utilizando también señales de MI filtradas, como se muestra en la Figura 1.10; sin embargo, este sistema empleaba un filtro espacial utilizando el Laplaciano, para luego aplicar un clasificador estadístico Gaussiano.



Figura 1.10: Usuario utilizando BCI para sostener un lapicero y escribir [32].

iii. Entretenimiento

Los videojuegos “atraen el interés de los investigadores y desarrolladores de las comunidades de BCI y juegos; sin embargo, se puede observar una discrepancia entre los juegos con BCI desarrollados por las dos comunidades” [33], ya que el enfoque que se les da desde la comunidad BCI busca una mayor eficiencia y control, pero a costo de experiencia de usuario y narrativa, elementos muy importantes durante el proceso de desarrollo de un videojuego.

Dependiendo del tipo de juego, se deberá usar un paradigma diferente, ya que cada género requiere de diferentes reacciones, reflejos y estimula al usuario de diferentes posibles formas [34]. Como se muestra en la Figura 1.11, la mayoría de juegos desarrollados con sistemas BCI son de acción, y las MI son el paradigma más utilizado en aplicaciones de esta área.




Figura 1.11: Gráficos de distribución de juegos desarrollados [34]. a) Distribución de juegos basados en BCI por género. b) Distribución de juegos basados en BCI por paradigma usado.

iv. Recuperación Motriz

“Actualmente la rehabilitación basada en neurociencia busca estimular la recuperación motora funcional espontánea capitalizando el potencial inherente del cerebro para la reorganización plástica luego de un derrame” [35]; es decir, aprovechando la capacidad de adaptación del cerebro. Aún no se conocen aplicaciones en esta área, pero se sabe el entrenamiento en MI puede producir aumentos significativos de performance tanto en motricidad como en la adaptación [36].

v. Monitoreo de Estados Mentales

Reconocer el estado mental del usuario permite crear sistemas BCI reactivos. Es posible reconocer el nivel de atención [37] del usuario mediante el análisis de las ondas alfa, beta y theta, utilizando un banco de filtros para separarlas según diferentes anchos de banda. También es posible obtener información sobre el nivel de fatiga [38], observando las amplitudes y tiempos de respuesta de los ERP y las ondas alfa y theta, con una ligera variación de exactitud promedio en función a

la frecuencia de corte de los filtros utilizados para eliminar artefactos de electro-miograma. Finalmente, se puede obtener información sobre el nivel de stress [39] del usuario, analizando las potencias de las ondas alfa con un clasificador lineal, de manera que este sea cuantificable, como se muestra en la Figura 1.12.

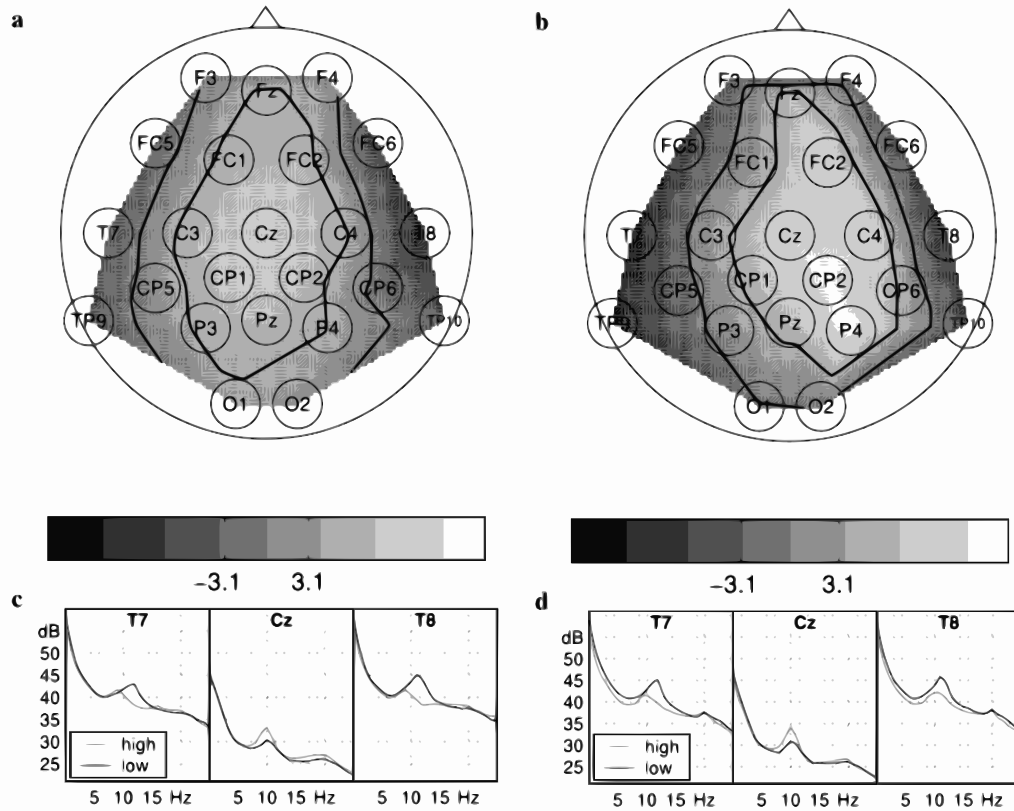


Figura 1.12: Diferencias espectrales en condiciones de alto y bajo stress [39].

1.2 Robótica Asistencial con BCI

En la actualidad, existen diversos prototipos que permiten a los usuarios manipular objetos o realizar ciertas tareas físicas con solo medir su actividad cerebral. Dichos prototipos suelen desarrollarse con objetivos principalmente académicos, pero la literatura también demuestra que dichos prototipos pueden ser utilizados para rehabilitación, o mejora de calidad de vida de personas con discapacidad [40].

Se puede definir como robot asistencial a aquellos que asisten o ayudan a usuarios

humanos [41]. En el contexto de personas que han padecido un ACV, y presentan alguna discapacidad motriz parcial o total, una prótesis u órtesis robótica, un brazo robótico montado sobre un soporte, o una silla de ruedas automática, serían ejemplos de robots asistenciales.

Las aplicaciones con sistemas BCI que tienen como periféricos a robots asistenciales se pueden dividir según la naturaleza del entorno con el que debe interactuar el usuario. Así, una aplicación que requiera acciones constantes, rápidas y sostenidas requerirá de imaginación de movimientos del usuario, mientras que una aplicación en la que el usuario dispone de tiempo para pensar antes de realizar una interacción puede permitir el empleo de SSEP, o ERP.

Uno de los desafíos más grandes para desarrollar una aplicación en tiempo real con BCI es la superposición de los diferentes métodos de procesamiento para cada uno de los paradigmas a utilizar [42]; por ejemplo, si una aplicación requiere clasificar por separado estados de reposo y acción para ambas manos del usuario, el sistema debería realizar el doble de procesamiento, además de las operaciones requeridas para el control de los periféricos, en una misma ventana de tiempo sin comprometer su rendimiento o aumentar los retardos. Adicionalmente, cada uno de los paradigmas debe ser entrenado por separado, lo que implica una mayor inversión de tiempo del usuario antes de poder interactuar con el sistema final.

1.2.1 Aplicaciones que utilizan ERD/ERS

Existe una gran variedad de aplicaciones que se desarrollan con sistemas BCI que utilizan ERD/ERS, con la mayoría de ellas basadas en la tarea mental de imaginación motriz. Debido a que esta tarea mental puede ser utilizada como parte de un procedimiento terapéutico para rehabilitación de pacientes que padecieron de ACV [43] [44], las aplicaciones que la utilizan encajan mayormente dentro del área de recuperación motriz. Algunos ejemplos de estas aplicaciones son los trabajos de Ang et al. [45] y Acuña et al. [46], en los cuales se realizan prótesis y órtesis,

mayormente con el objetivo de proveer realimentación cuantitativa al usuario sobre su progreso durante cada sesión. El prototipo desarrollado por Acuña et al. aparece en la Figura 1.13.




Figura 1.13: Prótesis de mano controlada con un sistema BCI [46].

Las aplicaciones basadas solo en ERD/ERS poseen, sin embargo, una limitación debido a que reproducir un movimiento similar al real para cualquier extremidad del cuerpo humano requiere de planificación de trayectorias y actualizaciones instantáneas de las mismas, según la interacción que se desee realizar con el entorno, lo cual depende de una gran cantidad de variables. Una BCI basada en imaginación motriz suele trabajar con una cantidad de clases reducida, entre dos y cuatro clases, usualmente, las cuales pueden estar acopladas entre sí en algunos casos, ya que la información que se puede obtener en una ventana de tiempo determinada, ya sea por la resolución espacial de los electrodos, o por las frecuencias a las que estos se muestrean es limitada. Una posible solución para este problema es la mencionada en el trabajo de Lalitharatne et al., en el que se propone el desarrollo de controladores híbridos que utilicen seales EEG y de electromiografía (EMG) para mejorar las imprecisiones [47]. El modelo descrito

para el control híbrido propuesto en este trabajo se muestra en la Figura 1.14.

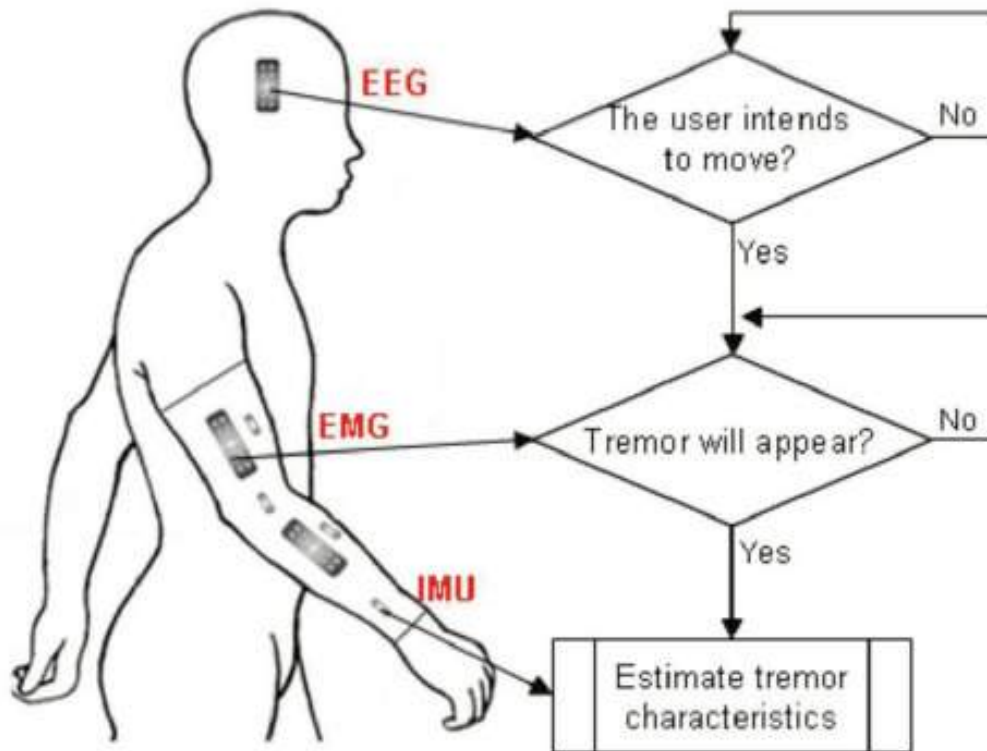


Figura 1.14: Diagrama de flujo de sistema integrado para control con EEG y EMG [47].

1.2.2 Aplicaciones que utilizan SSEP

Las aplicaciones con SSEP permiten, a diferencia de las que utilizan ERD/ERS, que los usuarios dispongan de una mayor cantidad de comandos; sin embargo, será necesario considerar las posibles combinaciones entre ellos como instrucciones adicionales, ya que el usuario solo puede concentrar su atención sobre un estímulo a la vez.

Mandel et al. desarrollaron un sistema que permitía al usuario elegir uno de trece posibles acciones de desplazamiento para una silla de ruedas autónoma [48]. Adicionalmente, en este trabajo se implementa un sistema de seguridad para evitar que la detección errónea de un comando enviado por el usuario no pueda causar algún tipo de accidente. El sistema implementado se puede apreciar en la

Figura 1.15.




Figura 1.15: Montaje de sistema para control de silla de rueda basado en SSEP [48].

1.2.3 Aplicaciones que utilizan ERP

Las aplicaciones de sistemas BCI que utilizan ERP suelen utilizar la componente P300 para seleccionar un objetivo dentro de una matriz de opciones previamente definidas, que no varía durante los experimentos. La principal ventaja de estas aplicaciones, frente a las dos alternativas mencionadas anteriormente, radica en que el tiempo que el usuario requiere realizar la tarea mental es significativamente menor, reduciendo también el impacto que se tiene sobre sus estados mentales

durante el uso del sistema. De igual manera, la mayor desventaja de usar un sistema basado en ERP es que el usuario no puede redefinir alguna de las tareas, a pesar de que se le podrán presentar una diversidad de opciones.

Un claro ejemplo que encaja con esta descripción es el trabajo de Bell et al., en el que se controla un pequeño robot humanoide para que se dirija e interactúe con un objeto seleccionado por el usuario [49]. La interfaz utilizada, en la que se muestran los posibles objetivos para la selección del usuario, así como el robot y su campo visual se muestran en la Figura 1.16.





Figura 1.16: Interfaz gráfica y robot humanoide controlado por sistema BCI [49].

Otro ejemplo en el que el usuario puede lograr cambios significativos en su entorno con este paradigma es el propuesto por Hoffmann et al. [50], en el que el usuario tendría control sobre elementos de su entorno, como un televisor, un teléfono, los controles de luz, etc., a partir de una matriz similar a la mostrada en la Figura 1.17. Es importante resaltar también que en este trabajo se logró una eficiencia de clasificación bastante alta al introducir un algoritmo que mejora cuando la

secuencia de estímulos se muestra más veces al usuario.



Figura 1.17: Interfaz gráfica utilizada para el experimento de Hoffmann et al [50].

CAPÍTULO 2

DESARROLLO DEL SISTEMA

El sistema desarrollado debe presentar una serie de estímulos visuales al usuario en un intervalo de tiempo para que se pueda activar la componente P300, relativa a los estímulos sobre los cuales se deposite la atención. En el presente capítulo se describen cada una de las partes que componen al sistema, ya sea como aplicaciones completas, módulos o algoritmos específicos, para finalmente proponer un modelo integrado de todas ellas.

2.1 Configuración Gráfica para el Usuario

La interfaz gráfica para el usuario; es decir, la matriz con los objetos que se presentan como estímulos al usuario, se implementó sobre un formulario en el lenguaje C#, utilizando el programa Microsoft Visual Studio Community 2017, creado por Microsoft Corporation. Este formulario también actúa como un servidor, ya que abre un puerto de comunicación TCP/IP para recibir la información que mostrará al usuario en un instante determinado. El diagrama de flujo que describe el funcionamiento de este módulo se puede apreciar en la Figura 2.1

Dentro del formulario existe una matriz de tamaño reconfigurable, con un máximo de opciones de seis, y un mínimo de una, de manera que se adapte con facilidad en caso de que se quisiera modificar la cantidad de estímulos. Adicionalmente, esta interfaz está diseñada para funcionar por niveles, de manera que el usuario puede navegar entre estos niveles para seleccionar diferentes tareas, sin tener que

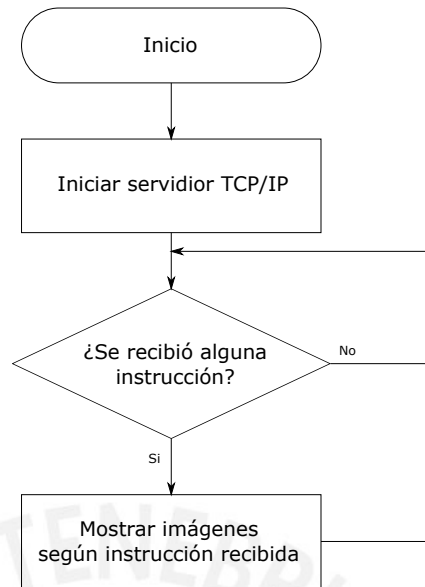


Figura 2.1: Diagrama de flujo de interfaz gráfica para el usuario. Fuente propia.

sobrecargar la cantidad de posibles estímulos en una configuración inicial única. Las Figuras 2.2 y 2.3 muestran algunos de los niveles de navegación, en los que la configuración espacial varía según el número de estímulos disponibles.




Figura 2.2: Primer nivel de navegación del sistema con dos posibles estímulos. Fuente propia.

Los niveles que el usuario por los cuales el usuario puede navegar son dos, siendo



Figura 2.3: Segundo nivel de navegación del sistema con tres posibles estímulos. Fuente propia.

el primero el que muestra la selección del dispositivo a controlar. Dentro de estas opciones se encuentran el robot asistencial a controlar, y un robot asistencial que se utiliza como distractor, sin tener impacto alguno al ser seleccionado. Luego de seleccionar el robot a controlar, se muestran las posibles tareas a realizar con un objeto predefinido. Este flujo de navegación se puede apreciar mejor en la Figura 2.4.

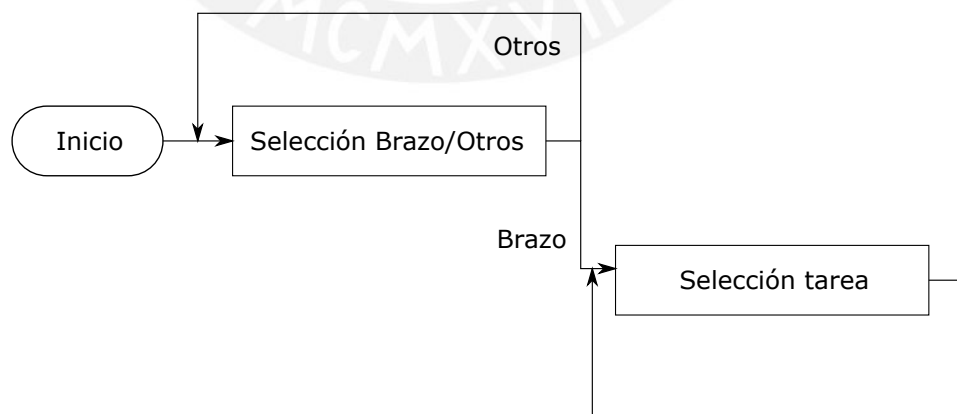


Figura 2.4: Flujo de navegación de interfaz para el usuario. Fuente propia.

2.2 Adquisición de Datos

La adquisición de datos se realizó con el EEG portátil inalámbrico g.Nutilus de la empresa g.tec Medical Engineering GmbH. Este dispositivo posee 32 electrodos secos, en posiciones establecidas por el Sistema Internacional 10/10, de los cuales se utilizan 16 (FP1, FP2, F3, FZ, F4, T7, C3, CZ, C4, T8, CP5, CP6, P3, PZ, P4, OZ), como se puede observar en la Figura 2.5, para muestrear las señales cerebrales a una frecuencia de 500Hz. Adicionalmente, se utilizan el programa MATLAB y su herramienta de simulación por bloques, Simulink, desarrollados por la empresa The Mathworks, Inc., para el desarrollo de todo el sistema de procesamiento e interpretación. La selección de utilizar Simulink como herramienta de procesamiento es válida debido a que todas las operaciones que se realizarán en intervalos críticos solo serán multiplicaciones matriciales, las cuales ya se encuentran optimizadas dentro de este paquete.

Todos los algoritmos relacionados con los siguientes pasos se implementaron también de manera síncrona en Simulink, además del envío de datos desde otro puerto de comunicación TCP/IP hacia la interfaz gráfica, haciendo que esta aplicación se comporte como un cliente. Finalmente, esta aplicación también se encarga de guardar los datos registrados por usuario, de manera que estos puedan ser útiles para análisis posteriores.

2.3 Preprocesamiento de Señales

Las señales eléctricas provenientes de los sensores de EEG contienen, además de ruido, información que puede ser relevante. Es por ello que se considera, en casi todos los sistemas BCI, la inclusión de uno o varios filtros digitales. Estos filtros tienen como objetivo el atenuar las componentes de frecuencia que son irrelevantes o innecesarias para el análisis. La función de transferencia de un filtro digital genérico tiene la forma mostrada en la ecuación 2.1, donde el orden

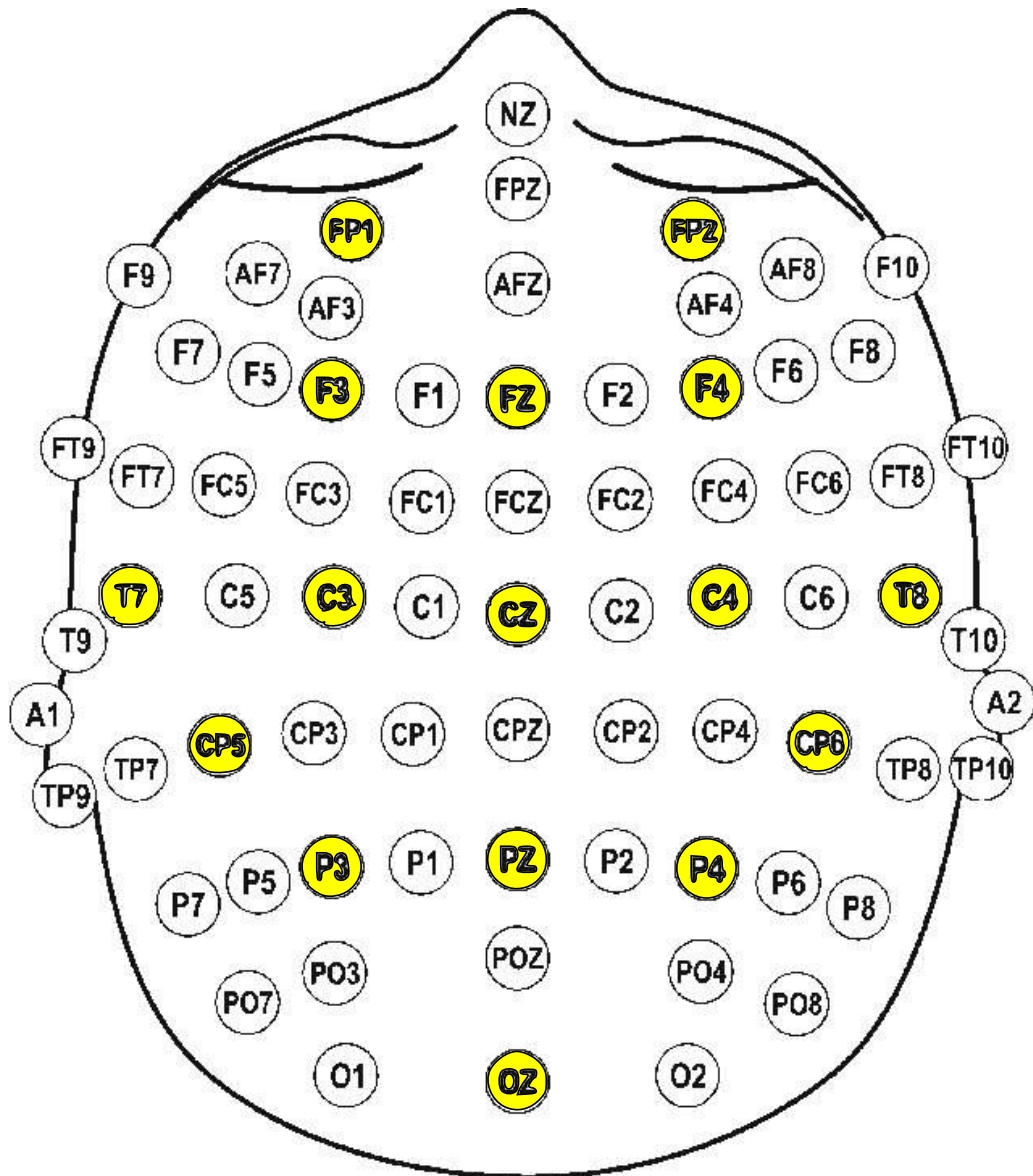


Figura 2.5: Posición de electrodos según Sistema Internacional 10/10. Los electrodos de color fueron los utilizados para realizar la adquisición de señales. Adaptado de [51].

del filtro es el valor mayor entre los valores N y M , y determina la atenuación o amplificación de las componentes armónicas de la señal de entrada.

$$H(z) = \frac{b_0 + b_1 * z^{-1} + b_2 * z^{-2} + \dots + b_N * z^{-N}}{1 + a_1 * z^{-1} + a_2 * z^{-2} + \dots + a_M * z^{-M}} \quad (2.1)$$

Debido a que la componente P300 a encontrar está en rangos de frecuencia bajos, ya que se podría representar como un pulso único o una función rectangular de

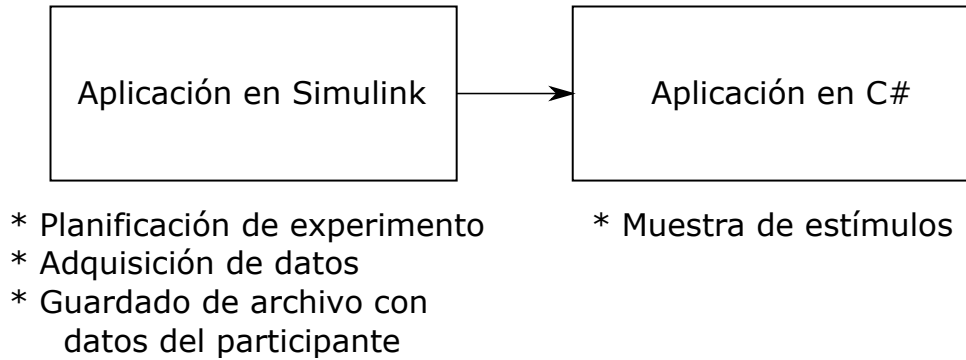


Figura 2.6: Esquema de comunicación entre aplicaciones de adquisición y muestra de estímulos. Fuente propia.

duración limitada, se elige un filtro pasabanda tipo Butterworth de orden diez con frecuencias de corte 1Hz y 15Hz, con el objetivo de eliminar frecuencias altas y valores constantes. La función de transferencia expandida como fracciones parciales de elementos reales para este filtro es la que aparece en la ecuación 2.2, y cuyos correspondientes diagramas de magnitud y fase se pueden apreciar en la Figura 2.7.

$$\begin{aligned}
 H(z) = & 4,099 * 10^{-6} + \frac{10^3 * (0,3126 * z^{-1} - 0,2937 * z^{-2})}{1 - 1,9996 * z^{-1} + 0,9997 * z^{-2}} \\
 & + \frac{0,3146 * z^{-1}}{1 - 0,9791 * z^{-1}} + \frac{-0,027 * z^{-1} + 0,0269 * z^{-2}}{1 - 1,9789 * z^{-1} + 0,9792 * z^{-2}} \\
 & + \frac{-0,0327 * z^{-1}}{1 - 0,9791 * z^{-1}} + \frac{-0,0703 * z^{-1} + 0,045 * z^{-2}}{1 - 1,8706 * z^{-1} + 0,9036 * z^{-2}} \\
 & + \frac{-0,1849 * z^{-1} + 0,1993 * z^{-2}}{1 - 1,7413 * z^{-1} + 0,7678 * z^{-2}}
 \end{aligned} \tag{2.2}$$

Adicionalmente, se sabe que la componente deseada aparece específicamente en un intervalo de tiempo definido, por lo que el procesamiento se realiza en una ventana de tiempo de un segundo a partir de cada estímulo. Finalmente, se realiza un submuestreo con razón de diez; es decir, se conserva solo una muestra cada diez puntos de datos obtenidos. Los resultados del preprocesamiento se pueden apreciar en la Figura 2.8, donde se puede diferenciar claramente un estímulo objetivo frente a un estímulo no objetivo, observando los picos de voltaje que




Figura 2.7: Diagramas de magnitud y fase para el filtro digital diseñado. Fuente propia.

aparecen alrededor de 300ms; es decir, cerca de la muestra número 15.

2.4 Extracción de Características

Luego de la adquisición de datos, se tienen señales provenientes de los 16 canales del EEG. Cada uno de estos canales posee 50 puntos de datos muestreados en el tiempo, por lo que la cantidad de datos con los que se estaría trabajando serían 800 puntos. La extracción de características es el procedimiento o secuencia de procedimientos que se utilizan para reducir significativamente la carga sobre el procesador y el tiempo de procesamiento, al reducir la cantidad de datos que se utilizan para el entrenamiento del algoritmo de clasificación mediante la selección de los valores que contengan mayor información representativa y el descarte del resto. La extracción de características es importante debido a que los algoritmos de aprendizaje de máquina que se emplean en sistemas BCI suelen requerir de una

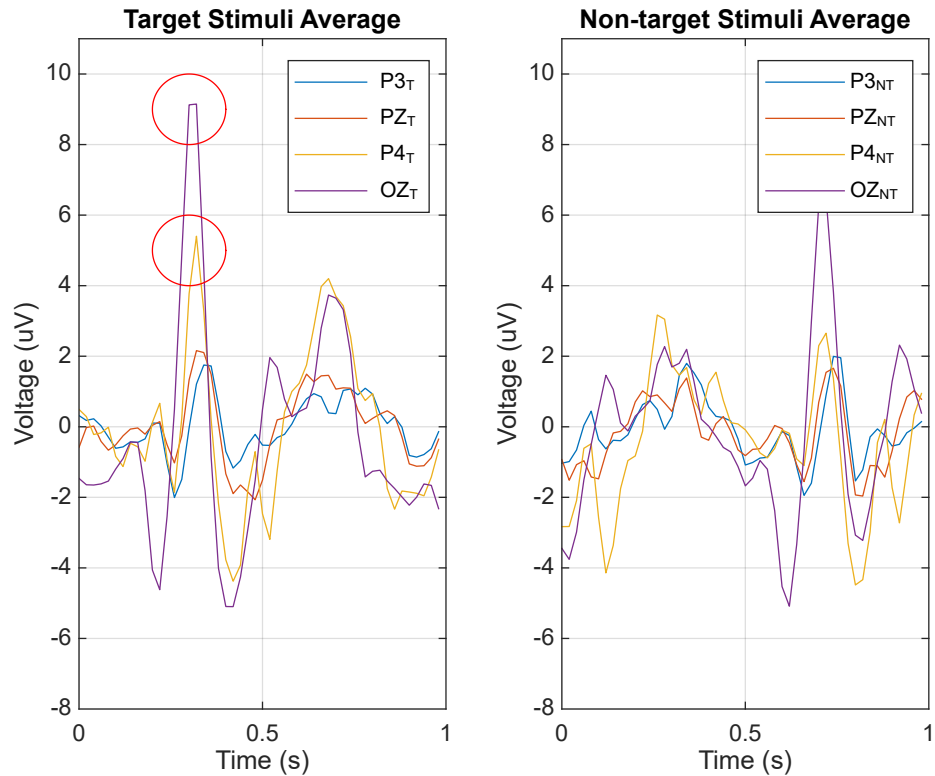


Figura 2.8: Señales para estímulo objetivo y estímulo no objetivo. Los canales mostrados son CP5, CP6, P3, PZ, P4 y OZ, según el Sistema Internacional 10/10. Fuente propia.

cantidad de tiempo directamente proporcional a una expresión que suele tener complejidad polinomial en función de la cantidad de datos, y estos son adquiridos en tiempo real.

El filtro de Patrones Espaciales Comunes (CSP) es un filtro espacial que consiste en una transformación lineal para separar una señal multivariable correspondiente a dos clases diferentes en componentes aditivas, de manera que estas presenten una máxima diferencia de varianza para una de las clases, y una diferencia mínima para la otra. “Debido a que la varianza de señales filtradas paso banda con el objetivo de obtener una efectiva discriminación de estados mentales caracterizados por efectos ERD/ERD” [52], por lo que resulta viable su uso para una BCI que solo requiere la diferenciación entre un estímulo objetivo y uno no objetivo.

El algoritmo CSP consiste en una diagonalización simultánea de dos matrices, cada una equivalente a la matriz de covarianza de una de las clases (R_1, R_2),

como se muestra en las ecuaciones 2.3 y 2.4 [53] [54]. Esto también se conoce como descomposición generalizada de valores propios. En dicho procedimiento, se debe encontrar una matriz cuadrada de vectores propios (P), y una matriz diagonal de valores propios ordenados de manera decreciente (D), lo cual es equivalente a la descomposición de de valores propios del producto de ambas matrices de covarianza originales. La ecuación 2.5 muestra la descomposición mencionada, mientras que el pseudocódigo para las funciones de filtrado y aprendizaje se pueden encontrar en los anexos 1 y 2, respectivamente.

$$P^{-1} * R_1 * P = D \quad (2.3)$$

$$P^{-1} * R_2 * P = I \quad (2.4)$$

$$R_2^{-1} * R_1 = P * D * P^{-1} \quad (2.5)$$

Luego, cada vector propio contenido en la matriz calculada; es decir, cada una de sus columnas, representa una de las componentes del nuevo espacio sobre el que se proyectarán las señales originales. Finalmente, basta con ordenar estos vectores propios según el orden decreciente de sus valores propios correspondientes, y tomar una cantidad de valores extremos superiores e inferiores para tener una nueva matriz de proyección (W) que será usada como filtro, quedando la data proyectada en el nuevo espacio, pero con una cantidad de señales reducida. Dicha proyección de las señales se muestra en la ecuación 2.6, y se puede apreciar para un conjunto de señales adquiridas durante los experimentos en la Figura 2.9. Es importante resaltar que las señales proyectadas en el nuevo espacio no necesariamente tienen alguna interpretación gráfica, o visible para el ojo humano.

$$X' = W * X \quad (2.6)$$

Debido a que los valores propios de ocho filtros superiores y ocho filtros inferiores

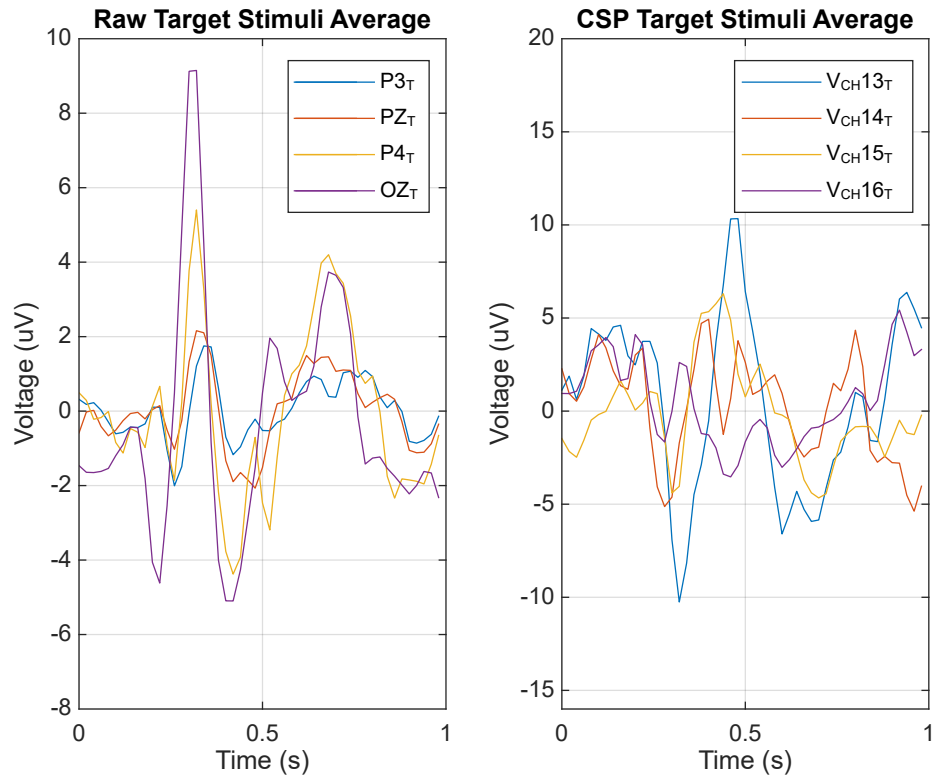


Figura 2.9: Señales para estímulo objetivo iniciales y filtradas con CSP. Fuente propia.

contenían la mayor cantidad de información sobre la separación de las clases en el subespacio proyectado, se considera adecuado la selección de ellos. Las señales proyectadas se muestran en la Figura 2.10, en la que se puede observar nuevamente la simetría entre el estímulo objetivo y el no objetivo.

Finalmente, se realiza un proceso de normalización de todos los canales para que las diferencias entre las magnitudes absolutas de las características que entren al clasificador no tengan influencia tanto sobre el proceso de entrenamiento, como durante la clasificación en tiempo real. El procedimiento realizado consiste en restar el valor medio del canal a cada muestra (μ_X), y luego dividir el valor obtenido sobre la desviación standard del mismo (σ_X), como se puede apreciar en la ecuación 2.7. Los nuevos canales normalizados se muestran en la Figura 2.11 para poder observar mejor el efecto de este procedimiento.




Figura 2.10: Características extraídas con CSP en el nuevo subespacio para señales de estímulo objetivo y estímulo no objetivo. Fuente propia.

$$X' = \frac{X - \mu_X}{\sigma_X} \quad (2.7)$$

2.5 Clasificación

Existen diversos métodos de clasificación de señales EEG. Dentro de los más utilizados, se encuentran los discriminantes lineales, los métodos de regresión, las redes neuronales y las máquinas de vectores de soporte [55]. Dentro de estos métodos, se seleccionó al algoritmo de discriminante lineal bayesiano (BLDA), descrito a continuación, con el cual se ha logrado la mayor eficiencia para sistemas basados en P300 [50].

Partiendo de la equivalencia entre la regresión con ajuste de mínimos cuadrados, y el análisis de discriminante lineal de Fisher (FLDA), se puede asumir que los




Figura 2.11: Características antes y después de normalización para estímulo objetivo. Fuente propia.

objetivos y las características están relacionados linealmente mediante una matriz de proyección (W). A este modelo se le añade ruido aditivo Gaussiano (E) para asemejar más a un procedimiento real, obteniéndose la expresión mostrada en la ecuación 2.8 [56].

$$T = W * X + E \quad (2.8)$$

De acuerdo con esta asunción, se puede escribir la función de probabilidad para el vector de pesos usado para la regresión, en función de la inversa de la varianza del ruido (β) y el número de muestras en el conjunto de entrenamiento (N), obteniéndose la ecuación 2.9.

$$p(X, T | \beta, W) = \left(\frac{\beta}{2 * \pi}\right)^{\frac{N}{2}} * e^{-\frac{\beta}{2} * \|X^T * W^T - T\|^2} \quad (2.9)$$

Adicionalmente, se sabe que, para realizar inferencia Bayesiana se requiere una distribución conocida a priori para la variable a calcular; es decir, al vector de pesos. Para ello, se utiliza una matriz cuadrada diagonal ($I'(\alpha)$) de dimensión igual al número de características aumentado en uno, como la mostrada en la ecuación 2.10, de manera que se obtenga la ecuación 2.11.

$$I'(\alpha) = \begin{bmatrix} \alpha & 0 & \cdots & 0 \\ 0 & \alpha & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \epsilon \end{bmatrix} \quad (2.10)$$

$$p(W|\alpha) = \left(\frac{\alpha}{2 * \pi}\right)^{\frac{D}{2}} * \left(\frac{\epsilon}{2 * \pi}\right)^{\frac{1}{2}} * e^{-\frac{1}{2} * W * I'(\alpha) * W^T} \quad (2.11)$$

Se sabe que es posible obtener la distribución posterior a partir de la conocida a priori y la función de distribución de probabilidad aplicando inferencia Bayesiana. Además, como ambas distribuciones son Gaussianas, la posterior también lo será, determinando la media (m) y covarianza (C) de esta utilizando las ecuaciones 2.12 y 2.13.

$$m = \beta * (\beta * X * X^T + I'(\alpha))^{-1} * X * t \quad (2.12)$$

$$C = (\beta * X * X^T + I'(\alpha))^{-1} \quad (2.13)$$

Multiplicando la ecuación de probabilidad por un vector de entrada con la distribución posterior, seguido de una integración sobre los pesos, se puede obtener la expresión que aparece en la ecuación 2.14, y representa la distribución de la predicción de los objetivos condicionados a dicho vector.

$$p(\hat{t}|\beta, \alpha, \hat{x}, D) = \int (p(\hat{t}|\beta, \hat{x}, W) * p(W|\beta, \alpha, D) * dW \quad (2.14)$$

Dicha distribución también es Gaussiana, y puede ser caracterizada por sus valores de media (μ) y varianza (σ), mostrados en las ecuaciones 2.15 y 2.16.

$$\mu = m^T * \hat{x} \quad (2.15)$$

$$\sigma^2 = \frac{1}{\beta} + \hat{x}^T * C * \hat{x} \quad (2.16)$$

Finalmente, es posible utilizar la suma de los valores de media por clase para seleccionar el valor de imagen de salida correspondiente al máximo entre ellos. El pseudocódigo para las funciones de clasificación y aprendizaje se encuentran en los anexos 3 y 4, respectivamente.

2.6 Comunicación con el Robot Asistencial

Una vez que se tiene la decisión de la acción física a ser realizada con el robot, esta es enviada desde el programa de Simulink hacia un entorno en C# no contemplado en el desarrollo de la presente, que se encarga de la correcta ejecución de la misma. El envío de los datos necesarios se realiza nuevamente por un puerto TCP/IP, diferente al utilizado para realizar la comunicación con la interfaz gráfica. Finalmente, la comunicación entre todos los programas necesarios para la BCI y el robot asistencial se muestran en la Figura 2.12.

2.7 Configuración Experimental

El último aspecto del sistema a diseñar es la configuración experimental. Dicha configuración es la que determina tanto la cantidad de datos que se deben adquirir, como la duración de cada proceso de adquisición. Cabe resaltar que esta selección de parámetros se realiza al final del desarrollo, por lo que el funcionamiento de un sistema BCI debe ser independiente de la modificación de ellos, sin ser necesaria alguna recompilación o reconstrucción de este.

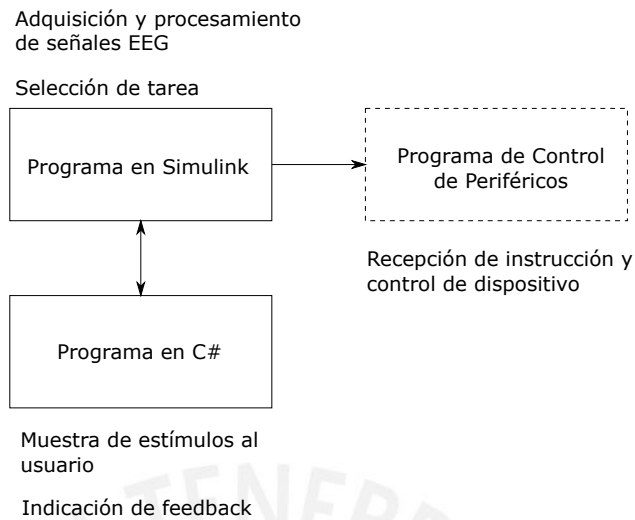


Figura 2.12: Esquema de comunicación entre todas las aplicaciones necesarias. Las líneas sólidas representan los componentes desarrollados en el presente trabajo. Fuente propia.

2.7.1 Definiciones Básicas

Antes de poder definir los experimentos a realizar, y sus respectivas duraciones, es necesario definir algunos conceptos previos. Estos conceptos, que pueden visualizarse ordenadamente en la Figura 2.13, se utilizan en la mayoría de los experimentos realizados en sistemas BCI, de manera que sea fácil realizar la diferenciación entre diversos trabajos que apuntan a objetivos similares.

Un ensayo o *trial*, para experimentos de sistemas BCI basados en ERP, consiste en una secuencia de estímulos distribuidos a lo largo de un intervalo de tiempo. Es posible que en algunos experimentos, un ensayo contenga solo un estímulo para cada objetivo, como en el caso del deletreador con P300, donde se tienen seis estímulos para las columnas, y seis estímulos para las filas, para un total de treinta y seis caracteres; sin embargo, cuando se dispone de una menor cantidad de elementos en la matriz visual, es posible repetirlos individualmente. Es importante resaltar que el usuario debe intentar permanecer concentrado a lo largo de todo




Figura 2.13: Diagrama de clases para entidades temporales de un sistema BCI.
Fuente propia.

el ensayo para poder realizar la tarea mental asignada correctamente, logrando una mayor eficiencia del sistema.

Una corrida o *run* consiste en un conjunto de ensayos consecutivos. Estos ensayos suelen estar separados por algunos segundos, en los que el usuario no requiere estar concentrado. Usualmente, cada ensayo está delimitado por dos estímulos diferentes a los relacionados con la tarea mental, uno al iniciar, y uno al finalizar, que se utilizan para que el sistema pueda mantener informado al usuario a lo largo del experimento.

Una sesión, como su nombre lo indica, abarca el conjunto de corridas que se realizan en una visita del usuario. Usualmente las sesiones se realizan en diferentes días, debido a que los experimentos suelen resultar prolongados y agotadores para los usuarios, además de que su duración promedio no es menor a media hora. Dentro de una sesión se pueden realizar las corridas que sean necesarias, separadas por algunos minutos en los que se le permite al usuario relajarse con el objetivo de reducir la posible fatiga provocada por las tareas mentales requeridas.

2.7.2 Experimento Fuera de Línea

El experimento de adquisición de datos para entrenamiento, también conocido como experimento fuera de línea, consiste en dos sesiones con doce corridas de diez ensayos cada una, separadas por aproximadamente cinco minutos. Cada ensayo inicia con un tiempo muerto inicial de un segundo, seguido de un indicador para el usuario con el estímulo objetivo que dura dos segundos. Luego se presenta otro tiempo muerto de un segundo, antes de empezar con la secuencia de estímulos aleatorizados. Finalmente, se tiene un segundo más de tiempo muerto antes de empezar inmediatamente el siguiente ensayo. Este flujo se puede observar en la Figura 2.14. Cabe rescatar que la adquisición para el entrenamiento solo se realizó con los estímulos de la pantalla principal, mostrada en la Figura 2.2; es decir, que el número de elementos en la matriz de ese nivel fue dos, entre los cuales se encuentra la opción del brazo a controlar.

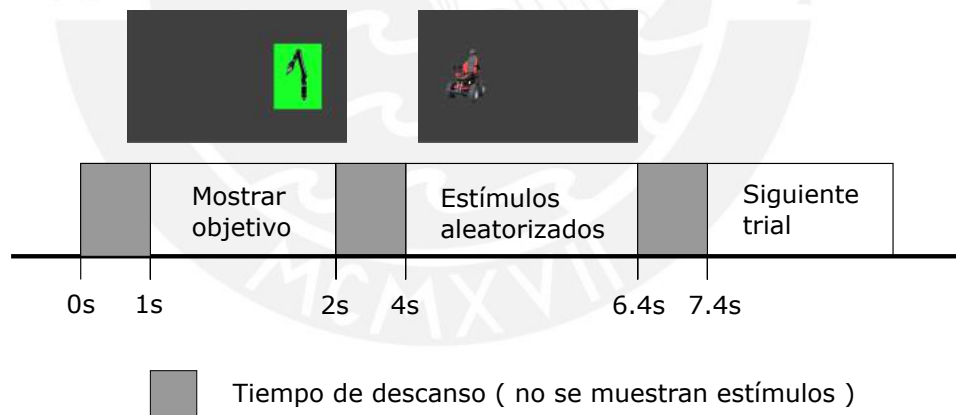


Figura 2.14: Línea de tiempo para un *trial* de adquisición. Fuente propia.

2.7.3 Experimento En Línea

El experimento de validación, o experimento en línea, se realiza en una única sesión de tres corridas, con cinco ensayos cada una, separadas también por aproximadamente cinco minutos. En cada corrida, el usuario debe lograr conseguir

navegar desde el nivel inicial hasta lograr que el robot ejecute una tarea seleccionada con un objeto específico. La secuencia de estímulos aleatorizada, de longitud variable (t) en función de la cantidad de imágenes que posea el nivel de navegación actual, se presentará un segundo después de una indicación tanto visual, mostrando el estímulo objetivo, como auditiva, para captar su atención. Adicionalmente, se presentará realimentación gráfica al usuario según su selección al terminar cada ensayo, para luego continuar al siguiente nivel de navegación o realizar la tarea seleccionada. El flujo descrito se puede apreciar en la Figura 2.15.

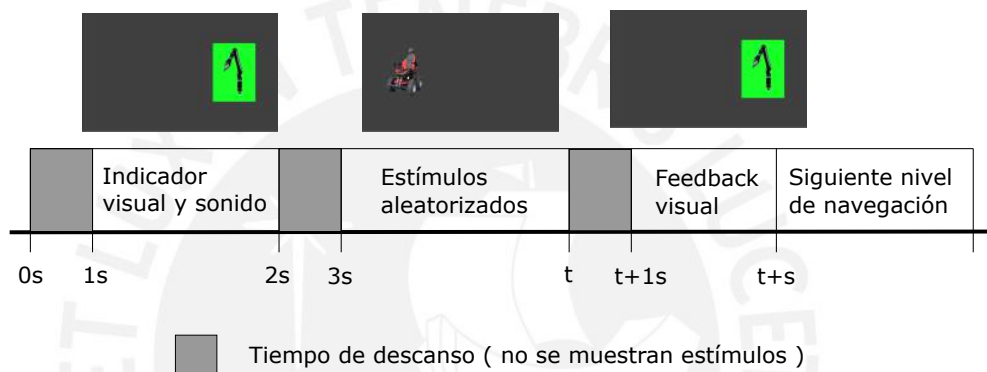


Figura 2.15: Línea de tiempo para un *trial* de validación. Los posibles valores para t están en función de la cantidad de elementos del nivel en el que se encuentre el usuario. Fuente propia.

2.7.4 Ambiente para Experimentación

En la mayoría de los trabajos realizados con sistemas BCI, los experimentos suelen realizarse en ambientes aislados de diversos tipos de ruido que podrían incomodar o distraer a los sujetos, o contaminar las señales adquiridas por los equipos. Uno de los elementos utilizados para realizar el aislamiento del ambiente para experimentación es la jaula de Faraday, para bloquear campos magnéticos [57]; mientras que, en otros casos, se utilizan ambientes aislados de sonido [58].

En el trabajo de Cutrell et al., se mencionan estos elementos como limitantes para que los sistemas BCI puedan ser utilizados fuera del mundo académico [59].

Debido a que el objetivo final del sistema desarrollado es poder ser utilizado por personas discapacitadas, se consideró prescindir de todos los elementos de aislamiento para analizar su verdadero potencial.



CAPÍTULO 3

RESULTADOS Y DISCUSIÓN

Se realizaron pruebas del sistema durante tres días diferentes con ocho usuarios, considerando como criterios de exclusión para estos que fueran menores de edad; es decir, que tuvieran menos de dieciocho años de edad en el momento de la adquisición de datos, además de aquellos usuarios que reportaban estar cansados, no haber dormido suficiente la noche anterior a las pruebas o que presentaban problemas para concentrarse durante el desarrollo de los experimentos.

3.1 Resultados de Entrenamiento

Luego de realizar la adquisición de datos, se realizó el entrenamiento del sistema. Para verificar que el sistema podrá funcionar adecuadamente, se realizó validación cruzada de K iteraciones, con un valor de seis para K ; es decir, que se separaron los datos adquiridos durante las dos primeras sesiones en seis grupos, y se repitió por cada uno de ellos el procedimiento de entrenar el sistema con los cinco restantes, para luego validarlo con el que se dejaba de lado.

Es importante resaltar que, durante la etapa de entrenamiento, se pudo observar que el algoritmo elegido siempre alcanzaba la convergencia, lo cual es sumamente importante para una clasificación correcta. Adicionalmente, se realizó un análisis para determinar la cantidad de repeticiones por estímulo óptima que se requeriría por usuario para que el sistema pueda detectar siempre correctamente el objetivo sobre el cual este centraba su atención, solo con fines de comprobar que la

selección de tres repeticiones por ensayo fue la correcta. La Figura 3.1 muestra los resultados de dicho análisis luego del proceso de validación cruzada.




Figura 3.1: Resultados de validación cruzada con seis grupos para el sujeto 1. Las líneas representan la exactitud de la predicción frente a la cantidad de repeticiones por estímulo mostrados en un ensayo para el i -ésimo grupo de datos. Fuente Propia.

Después de verificar que la validación cruzada fue satisfactoria, se entrenó al sistema con todos los datos, de manera que este quedara preparado para la sesión de validación. Esto se debe a que el objetivo de la validación cruzada no es el de construir un modelo, sino el de verificarlo. La Figura 3.2 muestra los resultados de dicho análisis para el clasificador entrenado con todos los datos, así como la cantidad de estímulos necesarios para la predicción correcta, con lo que se puede evidenciar que la selección inicial de tres fue correcta, mientras que los resultados, tanto de la validación cruzada, como del entrenamiento final para cada usuario se pueden encontrar en la Tabla 3.1.

Finalmente, promediando los resultados obtenidos con todos los usuarios, se pue-

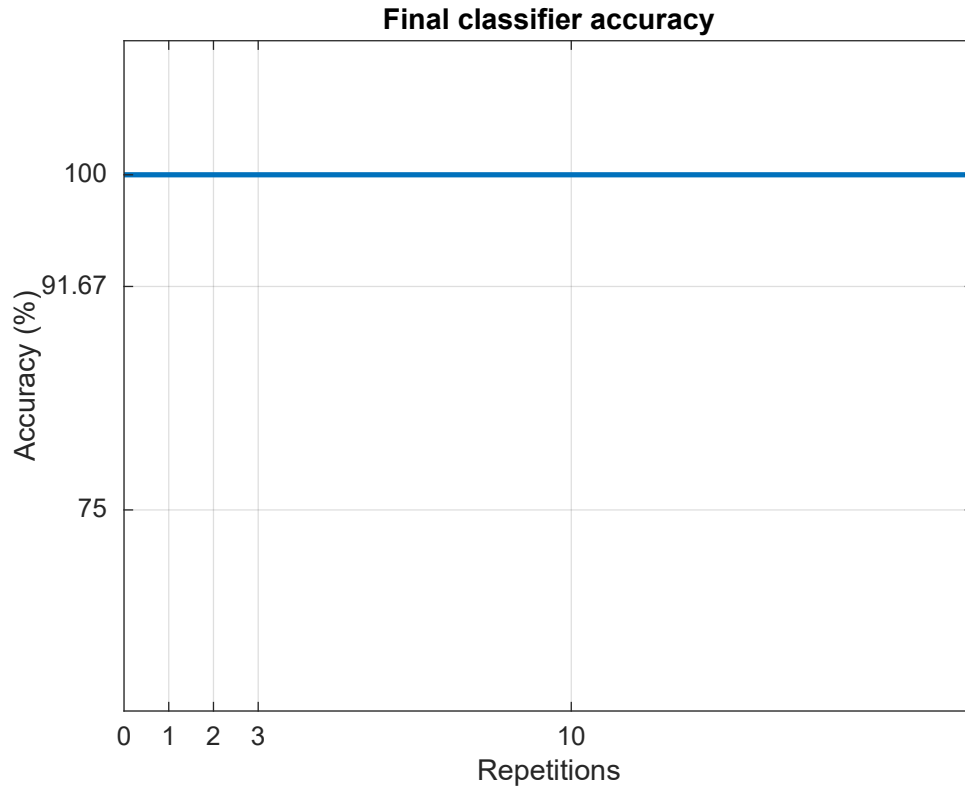


Figura 3.2: Resultados de entrenamiento de clasificador final para sujeto 1. La línea representa la exactitud de la predicción frente a la cantidad de repeticiones por estímulo mostrados en un ensayo. Fuente Propia.

Tabla 3.1: Resultados promedio con desviación standard para validación cruzada y entrenamiento final por usuario.

Usuario	Validación cruzada (%)	Entrenamiento final (%)
1	100 ± 0	100
2	100 ± 0	100
3	$85,12 \pm 5,271$	80,173
4	$94,443 \pm 8,608$	95,32
5	$75,58 \pm 9,362$	70,895
6	100 ± 0	95,83
7	$94,445 \pm 13,607$	95,83
8	$87,5 \pm 25$	83,333

Fuente propia.

de observar que la eficiencia promedio global para el proceso de entrenamiento es aproximadamente de 90.17%, un valor que se puede considerar como aceptable para este procedimiento, considerando que estas eficiencias podrían aumentar hasta el máximo admisible si es que se varía la cantidad de repeticiones considerada por estímulo; sin embargo, es necesario tomar en cuenta que el modificar el

número de repeticiones causaría también una variación proporcional en la duración de los experimentos.

3.2 Resultados de Validación

Para los resultados de la validación del sistema se tomaron en cuenta la cantidad de aciertos del usuario sobre el estímulo que se le había indicado como objetivo, además de la cantidad de intentos que le tomó pasar por los niveles iniciales hasta el nivel en el que se envía la tarea seleccionada al robot; es decir, las veces en las que el sistema no identificó correctamente el patrón deseado. Estos resultados se muestran por usuario en la Tabla 3.2.

Tabla 3.2: Resultados promedio con desviación standard para validación del sistema por usuario.

Usuario	Exactitud final (%)
1	100 ± 0
2	79 ± 3,606
3	70 ± 3,606
4	90 ± 3,559
5	70 ± 0
6	95 ± 0
7	95 ± 3,559
8	62 ± 4,082

Fuente propia.

Al igual que en la sección anterior, se puede analizar la eficiencia promedio global del sistema para los experimentos de validación, obteniéndose un valor aproximado de 82.62%. Una posible razón por la cual el valor obtenido es menor que el perteneciente a la etapa de entrenamiento sería la diferencia en los estados mentales de los usuarios al realizar la sesión de validación, generada debido a la expectativa de poder ver los resultados de las sesiones previas.

3.3 Resultados no Cuantitativos

Los resultados no cuantitativos reportados están, mayormente, basados en las observaciones realizadas por los usuarios sobre el sistema, y podrían tomarse en consideración para próximos estudios o para posibles mejoras del sistema desarrollado. Estas observaciones serán mencionadas a continuación; sin embargo, también pueden observarse en las Tablas 3.3 y 3.4, donde los valores van desde uno hasta siete, y representan que tan de acuerdo estuvieron los usuarios con cada uno de los aspectos del sistema, siendo siete el valor equivalente a “completamente de acuerdo”.

Tabla 3.3: Resultados no cuantitativos por usuario según método utilizado para concentrarse.

Usuario	Partes específicas de la imagen	Relación de forma con otros objetos	Conteo de estímulos	Otros
1	7	1	5	1
2	7	1	1	2
3	5	3	1	1
4	5	2	2	1
5	6	4	1	1
6	1	1	1	7
7	7	3	6	1
8	4	7	1	1

Fuente propia.

La principal observación de los usuarios se basó en que les fue más sencillo concentrarse únicamente sobre los estímulos aproximadamente desde la mitad de la primera sesión, alrededor del final de la tercera o cuarta corrida. Esto puede tener una relación con el umbral de aprendizaje humano necesario para que se acostumbren a realizar las tareas mentales solicitadas [60].

La estrategia que más usuarios reportaron notar para mejora de su concentración sobre el estímulo objetivo fue la de prestar mayor atención a una zona específica del objetivo, en lugar de la imagen completa, mientras que la segunda estrategia

Tabla 3.4: Resultados no cuantitativos por usuario según mejoras a realizarse para el sistema.

Usuario	Calidad de imágenes	Contraste	Diseño gráfico	Duración de experimentos
1	4	1	6	1
2	3	5	4	2
3	5	2	5	1
4	6	5	4	1
5	4	3	4	1
6	3	6	4	1
7	4	2	4	1
8	5	6	3	1

Fuente propia.

para facilitar la concentración más reportada por los usuarios fue la de relacionar la silueta del objeto mostrado en la imagen con alguna forma familiar similar.

Adicionalmente, algunos usuarios reportaron que la pantalla gris, el estado de relajación mental, la falta de movimiento y el aislamiento del ambiente en el que se realizaron las pruebas los condujo a una sensación de somnolencia, por lo que recomendaban modificaciones al contraste entre las imágenes y el color de fondo, ya que ambas eran oscuras, en caso se deseen realizar pruebas con una duración más prolongada.

Los usuarios también observaron que la duración de las sesiones era bastante prolongada, aproximadamente una hora en total por cada una desde la colocación de los equipos hasta la remoción de los mismos. Esto se debió a que, en la mayoría de los casos, se presentaban preguntas o conversaciones sobre temas aleatorios entre cada corrida, con el objetivo de disminuir el desgaste del usuario por la realización de las tareas mentales solicitadas. Sin embargo, debido a que el tiempo efectivo de la adquisición de datos fue entre doce y quince minutos, los usuarios no reportaron sentirse agotados como consecuencia de su participación en los experimentos.

Finalmente, se presentaron algunas situaciones en las que los usuarios se pre-

sentaron a la realización de las pruebas luego de estar bajo la presión de haber rendido evaluaciones académicas, por lo que no habían dormido suficientes horas para sentirse descansados. Esto a veces ocurrió luego de haberse realizado completamente la sesión del día, por lo que se descartaron los datos y se reprogramó la cita para un día posterior, ya que la literatura indica que las señales cerebrales para diversas tareas mentales presentan diferencias significativas cuando las personas están agotadas.



CONCLUSIONES

- Es posible utilizar el sistema desarrollado aplicando tecnología de interfaz cerebro-computador para seleccionar tareas para un robot asistencial. Esto no está limitado al brazo robótico utilizado durante los experimentos, sino a cualquier dispositivo periférico cuyo controlador requiera de instrucciones sencillas y de alto nivel para su funcionamiento.
- La exactitud obtenida para el sistema utilizando tres repeticiones por ensayo es lo suficientemente alta para demostrar la viabilidad del sistema; sin embargo, variando la cantidad de repeticiones podría obtenerse un sistema personalizado que entregue mayor eficiencia individual por cada usuario, a cambio de una menor velocidad de transferencia de datos, ya que el tiempo de duración de cada ensayo se incrementa en 400ms por cada repetición de cada estímulo.
- Las estrategias para mejorar la atención del usuario sobre los estímulos mostrados por el sistema resultaron intuitivas, ya que no fue necesario mencionarlas al realizar los experimentos, sino que fue suficiente con explicarles previamente el funcionamiento básico del mismo.
- Los comentarios de los usuarios fueron mayormente positivos, sobretodo luego de pasar la tercera sesión con el sistema, cuando lograron que el brazo realice las tareas seleccionadas; sin embargo, la principal mejora a considerar debería ser la estética de la interfaz gráfica, con el objetivo de hacerla aún más amigable e intuitiva, con una mejor calidad y distribución espacial de las imágenes.

RECOMENDACIONES

- Siguiendo los comentarios de los usuarios, para mejorar la apariencia del sistema, se deben realizar cambios a la interfaz, tanto en la resolución de las imágenes mostradas como estímulos, como en los elementos descriptores de cada tarea a ser realizada por el robot.
- En caso se desee aumentar más la exactitud de las predicciones del sistema, o realizar pruebas con personas que tengan dificultades para concentrarse, se puede recurrir a aislar el entorno en el cual se realicen los experimentos, de manera que hayan menos elementos distractores. Otros métodos a considerar podrían ser el aumento de la cantidad de corridas realizadas durante cada sesión, o el aumento de la cantidad de estímulos consecutivos a procesar para cada ensayo.
- En caso se desee probar el sistema con personas discapacitadas, se debe tener especial cuidado con la duración del experimento, ya que estas personas disponen de menos recursos para liberar el estrés generado durante cada corrida a realizar.

BIBLIOGRAFÍA

- [1] E. E. Fetz, “Operant conditioning of cortical unit activity,” *Science*, vol. 163, pp. 955–957, February 1969.
- [2] E. M. Schmidt, J. S. McIntosh, L. Durelli, and M. J. Bak, “Fine control of operantly conditioned firing patterns of cortical neurons,” *Experimental Neurology*, vol. 61, no. 2, pp. 349–369, 1978.
- [3] B. Allison, T. Lüth, D. Valbuena, A. Teymourian, and I. Volosyak, “BCI Demographics : How Many (and What Kinds of) People Can Use an SSVEP BCI?” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 18, no. 2, pp. 107–116, 2010.
- [4] C. Guger, B. Z. Allison, B. Großwindhager, R. Prückl, C. Hintermüller, C. Kapeller, M. Bruckner, G. Krausz, and G. Edlinger, “How many people could use an SSVEP BCI?” *Frontiers in Neuroscience*, vol. 6, p. 169, 2012.
- [5] J. R. Wolpaw, N. Birbaumer, W. J. Heetderks, D. J. McFarland, P. H. Peckham, G. Schalk, E. Donchin, L. A. Quatrano, C. J. Robinson, and T. M. Vaughan, “Brain-computer interface technology: A review of the first international meeting,” *IEEE Transactions on Rehabilitation Engineering*, vol. 8, no. 2, pp. 164–173, 2000.
- [6] A. Vallabhaneni, T. Wang, and B. He, *Neural Engineering*. Springer, 2005, ch. Brain-Computer Interface, pp. 85–121.

- [7] H. Berger, “Über das Elektrenkephalogramm des Menschen,” *Archiv fur Psychiatrie and Nervenkrankheiten*, vol. 87, no. 1, pp. 527–570., 1929.
- [8] J. J. Vidal, “Toward direct brain-computer communication,” *Annual Review of Biophysics and Bioengineering*, vol. 2, no. 1, pp. 157–180, 1973.
- [9] S. G. Mason and G. E. Birch, “A general framework for brain-computer interface design,” *IEEE Engineering in Medicine and Biology Society*, vol. 11, no. 1, pp. 70–85, 2003.
- [10] P. Olejniczak, “Neurophysiologic basis of the EEG,” *Journal of Clinical Neurophysiology*, vol. 23, no. 3, pp. 186–189, 2006.
- [11] S. Giménez, “Qué es un Electroencefalograma?” 2011. [Online]. Available: <https://www.medicina21.com/Articulos-V1178.html>
- [12] Y.-H. Chiou, J.-J. Luh, S.-C. Chen, J.-S. Lai, and T.-S. Kuo, “The comparison of electromyographic pattern classifications with active and passive electrodes,” *Medical Engineering and Physics*, vol. 26, no. 7, pp. 605–610, 2004.
- [13] M. A. Lopez-Gordo, D. Sanchez-Morillo, and F. Pelayo Valle, “Dry EEG electrodes,” *Sensors (Basel, Switzerland)*, vol. 14, no. 7, pp. 12 847–12 870, 2014.
- [14] V. Jurcak, D. Tsuzuki, and I. Dan, “10/20, 10/10, and 10/5 systems revisited: Their validity as relative head-surface-based positioning systems,” *NeuroImage*, vol. 34, no. 4, pp. 1600–1611, 2007.
- [15] G. H. Klem, H. O. Lüeders, H. Jasper, and C. Elger, “The ten-twenty electrode system of the International Federation,” *Electroencephalography and Clinical Neurophysiology*, vol. 52, no. 3, pp. 3–6, 1999.
- [16] S. Sur and V. K. Sinha, “Event-related potential: An overview,” *Industrial Psychiatry Journal*, vol. 18, no. 1, pp. 70–73, 2009.

- [17] E. Donchin, K. M. Spencer, and R. Wijesinghe, “The mental prosthesis: Assessing the speed of a P300-based brain-computer interface,” *IEEE Transactions on Rehabilitation Engineering*, vol. 8, no. 2, pp. 174–179, 2000.
- [18] P. W. Ferrez and J. D. R. Millán, “Error-Related EEG Potentials Generated During Simulated Brain-Computer Interaction,” *IEEE Transactions on Biomedical Engineering*, vol. 55, no. 3, pp. 923–929, 2008.
- [19] D. Regan, “Some characteristics of average steady-state and transient responses evoked by modulated light,” *Clinical Neurophysiology*, vol. 20, no. 3, pp. 238–248, 1966.
- [20] M. M. Müller, T. W. Picton, P. Valdes-Sosa, J. Riera, W. A. Teder-Sälejärvi, and S. A. Hillyard, “Effects of spatial selective attention on the steady-state visual evoked potential in the 20-28 Hz range,” *Cognitive Brain Research*, vol. 6, no. 4, pp. 249–261, 1998.
- [21] S. T. Morgan, J. C. Hansen, and S. A. Hillyard, “Selective attention to stimulus location modulates the steady-state visual evoked potential.” *Proceedings of the National Academy of Sciences of the United States of America*, vol. 93, no. 10, pp. 4770–4774, 1996.
- [22] R. Galambos, S. Makeig, and P. J. Talmachoff, “A 40-Hz auditory potential recorded from the human scalp,” *Proceedings of the National Academy of Sciences*, vol. 78, no. 4, pp. 2643–2647, 1981.
- [23] T. Wilding, C. McKay, R. Baker, and K. Kluk, “Auditory Steady-State Responses in Normally Hearing and Hearing-Impaired Adults: An analysis of between session amplitude and latency repeatability, test time and F-Ratio detection paradigms.” *Ear and Hearing*, vol. 33, no. 2, pp. 267–278, 2012.
- [24] H. Higashi, T. M. Rutkowski, Y. Washizawa, A. Cichocki, and T. Tanaka, “EEG auditory steady state responses classification for the novel BCI,” in

Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS, 2011, pp. 4576–4579.

- [25] G. Pfurtscheller and F. H. Lopes Da Silva, “Event-related EEG/MEG synchronization and desynchronization: Basic principles,” *Clinical Neurophysiology*, vol. 110, no. 11, pp. 1842–1857, 1999.
- [26] R. Leeb and J. D. R. Millán, “Introduction to Devices, Applications and Users: Towards Practical BCIs Based on Shared Control Techniques,” in *Towards Practical Brain-Computer Interfaces*, 2012, pp. 107–129.
- [27] H.-J. Hwang, J.-H. Lim, Y.-J. Jung, H. Choi, S. W. Lee, and C.-H. Im, “Development of an SSVEP-based BCI spelling system adopting a QWERTY-style LED keyboard,” *Journal of Neuroscience Methods*, vol. 208, no. 1, pp. 59–65, 2012.
- [28] D. J. Krusienski, E. W. Sellers, F. Cabestaing, S. Bayouth, D. J. McFarland, T. M. Vaughan, and J. R. Wolpaw, “A comparison of classification techniques for the P300 Speller.” *Journal of neural engineering*, vol. 3, no. 4, pp. 299–305, 2006.
- [29] S. Inoue, Y. Akiyama, Y. Izumi, and S. Nishijima, “The development of BCI using alpha waves for controlling the robot arm,” *IEICE Transactions on Communications*, vol. 91, no. 7, pp. 2125–2132, 2008.
- [30] L. Kirkup, A. Searle, A. Craig, P. Mclsaac, and P. Moses, “EEG-based system for rapid on-off switching without prior learning,” *Medical and Biological Engineering and Computing*, vol. 35, no. 5, pp. 504–509, 1997.
- [31] G. Pfurtscheller, G. R. Müller, J. Pfurtscheller, H. J. Gerner, and R. Rupp, “‘Thought’ - Control of functional electrical stimulation to restore hand grasp in a patient with tetraplegia,” *Neuroscience Letters*, vol. 351, no. 1, pp. 33–36, 2003.

- [32] M. Tavella, R. Leeb, R. Rupp, and J. d. R. Millán, “Towards natural non-invasive hand neuroprostheses for daily living,” in *Proceedings of the 2010 IEEE Annual International Conference on Engineering in Medicine and Biology Society*, 2010, pp. 126–129.
- [33] H. Gürkök, A. Nijholt, and M. Poel, “Brain-computer interface games: Towards a framework,” in *Proceedings of the International Conference on Entertainment Computing*, 2012, pp. 373–380.
- [34] D. Marshall, D. Coyle, S. Wilson, and M. Callaghan, “Games, gameplay, and BCI: The state of the art,” *IEEE Transactions on Computational Intelligence and AI in Games*, vol. 5, no. 2, pp. 82–99, 2013.
- [35] J. d. R. Millán, R. Rupp, G. R. Müller-Putz, R. Murray-Smith, C. Giugliemma, M. Tangermann, C. Vidaurre, F. Cincotti, A. Kübler, R. Leeb, C. Neuper, K.-R. Müller, and D. Mattia, “Combining brain-computer interfaces and assistive technologies: State-of-the-art and challenges,” *Frontiers in Neuroscience*, vol. 4, p. 161, 2010.
- [36] M. Lotze and U. Halsband, “Motor imagery,” *Journal of Physiology Paris*, vol. 99, no. 4-6, pp. 386–395, 2006.
- [37] B. Hamadicharef, H. Zhang, C. Guan, C. Wang, S. P. Kok, P. T. Keng, and K. A. Kai, “Learning EEG-based spectral-spatial patterns for attention level measurement,” in *Proceedings - IEEE International Symposium on Circuits and Systems*, 2009, pp. 1465–1468.
- [38] L. J. Trejo, K. Knuth, R. Prado, R. Rosipal, K. Kubitz, R. Kochavi, B. Matthews, and Y. Zhang, “EEG-based estimation of mental fatigue: Convergent evidence for a three-state model,” in *Proceedings of the International Conference on Foundations of Augmented Cognition*, 2007, pp. 201–211.
- [39] J. Kohlmorgen, G. Dornhege, M. L. Braun, B. Blankertz, K.-R. Müller, G. Curio, K. Hagemann, A. Bruns, M. Schrauf, and W. E. Kincses, “Impro-

ving Human Performance in a Real Operating Environment through Real-Time Mental Workload Detection,” in *Toward Brain-Computer Interfacing*, 2007, pp. 409–422.

- [40] D. G. Mackay, “The problem of rehearsal or mental practice,” *Journal of Motor Behavior*, vol. 13, no. 4, pp. 274–285, 1981.
- [41] D. J. Feil-Seifer and M. J. Matarić, “Defining Socially Assistive Robotics,” in *Proceedings of the 2005 IEEE 9th International Conference on Rehabilitation Robotics*, 2005, pp. 465–468.
- [42] G. Pfurtscheller, B. Z. Allison, C. Brunner, G. Bauernfeind, T. Solis-Escalante, R. Scherer, T. O. Zander, G. R. Müller-Putz, C. Neuper, and N. Birbaumer, “The hybrid BCI,” *Frontiers in Neuroscience*, vol. 4, no. April, p. 3, 2010.
- [43] N. Sharma, J. C. Baron, and J. B. Rowe, “Motor imagery after stroke: Relating outcome to motor network connectivity,” *Annals of Neurology*, vol. 66, no. 5, pp. 604–616, 2009.
- [44] A. Zimmermann-Schlatter, C. Schuster, M. A. Puhan, E. Siekierka, and J. Steurer, “Efficacy of motor imagery in post-stroke rehabilitation: A systematic review,” *Journal of NeuroEngineering and Rehabilitation*, vol. 5, no. 1, p. 8, 2008.
- [45] K. K. Ang, C. Guan, K. S. G. Chua, B. T. Ang, C. Kuah, C. Wang, K. S. Phua, Y. Zheng Chin, and H. Zhang, “Clinical study of neurorehabilitation in stroke using EEG-based motor imagery brain-computer interface with robotic feedback,” in *Proceedings of the 2010 Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 2010, pp. 5549–5552.
- [46] K. Acuña Condori, E. Carranza Urquizo, and D. Achanccaray Diaz, “Embedded brain machine interface based on motor imagery paradigm to control

- prosthetic hand,” in *Proceedings of the 2016 IEEE ANDESCON*, October 2016.
- [47] T. D. Lalitharatne, K. Teramoto, Y. Hayashi, and K. Kiguchi, “Towards hybrid EEG-EMG-based control approaches to be used in bio-robotics applications: Current status, challenges and future directions,” *Paladyn, Journal of Behavioral Robotics*, vol. 4, no. 2, pp. 147–154, 2013.
- [48] C. Mandel, T. Lüth, T. Laue, T. Röfer, A. Gräser, and B. Krieg-Brückner, “Navigating a smart wheelchair with a brain-computer interface interpreting steady-state visual evoked potentials,” in *2009 IEEE/RSJ International Conference on Intelligent Robots and Systems*, 2009, pp. 1118–1125.
- [49] C. J. Bell, P. Shenoy, R. Chalodhorn, and R. P. Rao, “Control of a humanoid robot by a noninvasive brain-computer interface in humans,” *Journal of Neural Engineering*, vol. 5, no. 2, pp. 214–220, 2008.
- [50] U. Hoffmann, J.-M. Vesin, T. Ebrahimi, and K. Diserens, “An efficient P300-based brain-computer interface for disabled subjects,” *Journal of Neuroscience Methods*, vol. 167, no. 1, pp. 115–125, 2008.
- [51] G. L. Iverson, B. L. Brooks, M. R. Schoenberg, and J. G. Scott, *The Little Black Book of Neuropsychology: A Syndrome-Based Approach*, 2011.
- [52] D. Steyrl, R. Scherer, O. Förstner, and G. R. Müller-Putz, “Motor Imagery Brain-Computer Interfaces : Random Forests vs Regularized LDA - Non-linear Beats Linear,” in *Proceedings of the 6th International Brain-Computer Interface Conference*, 2014, pp. 8–11.
- [53] Z. J. Koles, M. S. Lazar, and S. Z. Zhou, “Spatial patterns underlying population differences in the background EEG,” *Brain Topography*, vol. 2, no. 4, pp. 275–284, 1990.
- [54] J. Müller-Gerking, G. Pfurtscheller, and H. Flyvbjerg, “Designing optimal

- spatial filters for single-trial EEG classification in a movement task,” *Clinical Neurophysiology*, vol. 110, no. 5, pp. 787–798, 1999.
- [55] D. J. McFarland, C. W. Anderson, K.-R. Müller, A. Schlögl, and D. J. Krusienski, “BCI Meeting 2005 - Workshop on BCI signal processing: Feature extraction and translation,” *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 14, no. 2, pp. 135–138, 2006.
- [56] C. M. Bishop, *Pattern Recognition and Machine Learning*, 2006.
- [57] Y. Liu, H. Ayaz, A. Curtin, P. A. Shewokis, and B. Onaral, “Detection of attention shift for asynchronous P300-based BCI,” in *Proceedings for the 2012 Annual International Conference of the IEEE in Engineering in Medicine and Biology Society (EMBC)*, 2012, pp. 3850–3853.
- [58] F. Bocquelet, T. Hueber, L. Girin, P. Badin, and B. Yvert, “Robust articulatory speech synthesis using deep neural networks for BCI applications,” in *Fifteenth Annual Conference of the International Speech Communication Association*, 2014.
- [59] E. Cutrell and D. Tan, “BCI for passive input in HCI,” in *Proceedings of CHI*, 2008, pp. 1–3.
- [60] F. Lotte and C. Jeunet, “Towards Improved BCI based on Human Learning Principles,” in *3rd International Winter Conference on Brain-Computer Interfaces*, 2015, pp. 1–4.

ANEXOS

Algorithm 1 Patrones Espaciales Comunes - filtrado

```
1: function CSPFILTER( $X$ ,  $filters$ )
2:    $output \leftarrow filters * X$ 
3:   return output
4: end function
```

Algorithm 2 Patrones Espaciales Comunes - entrenamiento

```
1: function CSPTRAIN( $X_1$ ,  $X_2$ ,  $n$ )
2:    $C_1 \leftarrow cov(X_1)$ 
3:    $C_2 \leftarrow cov(X_2)$ 
4:    $C \leftarrow C_2^{-1} * C_1$ 
5:    $[\sim, S, V] \leftarrow svd(C)$ 
6:    $whitening \leftarrow \sqrt{S^{-1}} * V$ 
7:    $[U, \sim, \sim] \leftarrow svd(whitening * C1)$ 
8:    $output \leftarrow [U_{1:n}, U_{n:end}] * whitening$ 
9:   return output
10: end function
```

Algorithm 3 Análisis de Discriminante Lineal Bayesiano - clasificación

```
1: function BLDACCLASSIFY( $X$ ,  $weights$ )
2:    $output \leftarrow weights * X$ 
3:   return output
4: end function
```

Algorithm 4 Análisis de Discriminante Lineal Bayesiano - entrenamiento

```
1: function BLDATRAIN( $X, Y, precision$ )
2:    $[V, D] \leftarrow eig(X * X^T)$ 
3:    $VY \leftarrow V^T * X * Y^T$ 
4:    $d\alpha \leftarrow \infty$ 
5:    $d\beta \leftarrow \infty$ 
6:   while  $d\alpha > precision$  or  $d\beta > precision$  do
7:      $M \leftarrow \beta * V * ((\beta * D + \alpha * I)^{-1} * VY)$ 
8:      $error \leftarrow sum((Y - M^T * X)^2)$ 
9:      $\gamma \leftarrow sum(\beta * D / (\beta * D + \alpha * I))$ 
10:     $n\alpha \leftarrow \gamma / (M^T * M)$ 
11:     $d\alpha \leftarrow abs(\alpha - n\alpha)$ 
12:     $n\beta \leftarrow (n(X, 1) - \gamma) / error$ 
13:     $d\beta \leftarrow abs(\beta - n\beta)$ 
14:     $[\alpha, \beta] \leftarrow [n\alpha, n\beta]$ 
15:   end while
16:    $output \leftarrow M$ 
17:   return output
18: end function
```
